(19)日本国特許庁(JP)

(12) 公開特許公報(A)

(11)特許出願公開番号

特開平9-265379

(43)公開日 平成9年(1997)10月7日

(51) Int.Cl. ⁶		識別記号	庁内整理番号	FΙ				技術表示箇所
G06F	3/16	320		G06F	3/16		3 2 0 B	
							3 2 0 A	
	3/14	3 1 0			3/14		310B	
G06T	1/00			G09G	5/00		510H	
G 0 9 G	5/00	510		G 1 0 L	3/00		551G	
			審查請求	未請求 請求	項の数15	OL	(全 36 頁)	最終頁に続く
				1				

(21)出願番号	特願平9-26968
----------	------------

(22)出願日 平成9年(1997)2月10日

(31)優先権主張番号96027016(32)優先日1996年2月9日(33)優先権主張国イギリス(GB)

(71)出願人 000001007

キヤノン株式会社

東京都大田区下丸子3丁目30番2号

(72)発明者 エリ ツィルケルーハンコック

イギリス国 ジーユー4 7エイチエイチ スアレイ、 ギルドフォード グリーン

ヒルガーデンズ 50

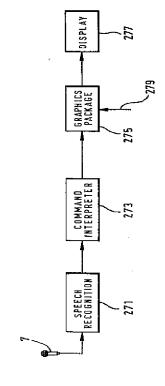
(74)代理人 弁理士 大塚 康徳 (外1名)

(54) 【発明の名称】 画像操作装置及び方法

(57)【要約】

【課題】 色編集用語または色操作ツールを用いることなく、画像を編集できる画像操作装置および方法を提供する。

【解決手段】 画像の色を操作する装置は、ユーザコマンドを示す電気音声信号を供給するマイクロフォン7、入力音声信号を認識する音声認識装置271、認識音声を解釈するコマンドインタプリタ273、コマンドインタプリタに応答するグラフィックパッケージ275および編集されるべき画像を表示するディスプレイ277を備える。本装置は、例えばポインティング装置からの他の入力279を受け入れる。



【特許請求の範囲】

【請求項1】 画像を再生する画像再生手段と、

前記再生画像に対する所望の色変化を表わす表現を含む 音声信号の入力を可能とする音声認識ユーザインタフェ ースと

前記音声認識インタフェースから出力された認識結果を 解釈する解釈手段と、

前記解釈手段に応答して、ユーザが必要とするカラー操作を行うべく、前記再生画像の1つ以上の部分の色を変化させる変化手段とを備えることを特徴とする画像操作装置。

【請求項2】 前記画像再生手段は表示装置を備え、当該装置は、変化されるべき表示画像の1つ以上の領域を指定する指定手段を更に備えることを特徴とする請求項1に記載の画像操作装置。

【請求項3】 請求項2記載の装置において:前記指定 手段は、変化されるべき領域を移動するポインティング デバイスであり、前記変化手段は、前記ポインティング デバイスによってたどられる画素の色相値の統計的特徴 を決定し、決定された統計的特徴と類似する色相値を有 する画像のすべての画素の色相値を変化させることを特 徴とする請求項2に記載の画像操作装置。

【請求項4】 前記変化手段は、前記ポインティングデバイスによってたどられた画素の平均値および標準偏差値を決定し、該決定された平均値を中心とした該決定された標準偏差の範囲内にある色相値を有する当該画像内のすべての画素を、前記変化手段によって変化させることを特徴とする請求項3に画像操作装置。

【請求項5】 色相変化の量が、所望の色変化の色相値に依存することを特徴とする請求項3または4記載の画像操作装置。

【請求項6】 前記画像再生手段は、印刷装置を備えることを特徴とする請求項1乃至5のいずれかに記載の画像操作装置。

【請求項7】 請求項1乃至6のいずれかに記載の画像 操作装置を有することを特徴とするコンピュータ。

【請求項8】 請求項1乃至6のいずれかに記載の画像 操作装置を有することを特徴とするファクシミリ装置。

【請求項9】 請求項1乃至6のいずれかに記載の画像 操作装置を有することを特徴とする複写装置。

【請求項10】 請求項1乃至6のいずれかに記載の画像操作装置を有することを特徴とするカメラ。

【請求項11】 音声認識ユーザインタフェースを用いて、ユーザによって発声入力された所望の色変化に関する文に対する認識結果を出力し、

出力された認識結果を解釈し、画像の全体もしくは部分 の色を変化させ、ユーザが所望する色操作を行うことを 特徴とする画像操作方法。

【請求項12】 前記画像が画像を操作する前に再生されることを特徴とする請求項11に記載の画像操作方

法。

【請求項13】 請求項11または12に記載の方法を 実行するソフトウェアがプログラムされたデータ搬送媒 体。

【請求項14】 添付図面の図36から図38を参照して記述されるように、音声コマンドによって実質的な画像の色操作を行う画像操作方法。

【請求項15】 添付図面の図36から図38を参照して記述されるように、画像の色操作行う画像操作装置。 【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、画像を操作する方法および装置に関する。特に、本発明は、コンピュータグラフィックシステムにおける画像の色操作に好適なものである。

[0002]

【従来の技術】今日のコンピュータグラフィックシステムは複雑で、画像の色を操作する多くの処理オプションをユーザに提供する。このようなシステムにおいて、ユーザは、画像の色を記述するために用いられる、例えば、色相、明度および彩度等の専門用語を十分理解し、所望の画像の色操作をするために提供された色操作ツールに精通していなければならない。

[0003]

【発明が解決しようとする課題】EP594129(出願人:日立製作所)には、ポインティングデバイスとともに音声によって制御されるグラフィックパッケージが開示されている。画像内のオブジェクトを移動させたり、画像内でパンやズームを行う処理が想定されている。しかしながら、EP594129には、画像の一部または複数部分の色を操作する場合に生じる困難な問題について記載されていない。

【0004】本発明は上記従来技術に鑑みてなされたものであり、色操作を表現する音声入力によって画像操作を行うことを可能とし、容易に所望の画像操作を行える画像操作装置及び方法を提供することを目的とする。

[0005]

【課題を解決するための手段】本発明の一態様による画像操作装置は、画像を再生する手段と、ユーザが再生画像に行われた所望の色変更の内容表現を有する音声信号を入力可能とする音声認識ユーザインタフェースと、ユーザが必要とする色操作を行うため一つまたはそれ以上の部分の再生画像の色を変更する手段とを備える。

【0006】また、変化させるべき画像の部分は、変化させるべき領域内の画素の色相値のサンプルを取るために用いられるポインティングデバイスによって指示されてもよい。

【0007】本発明の別の態様による画像操作方法は、 操作されるべき画像を再生し、音声認識ユーザインタフェースを用いてユーザが発声入力した所望の色変化の内 容表現に対する認識結果を出力し、認識結果出力を解釈 してユーザが必要とする色操作を遂行すべく再生画像を 全体的にまたは部分的に変化させる。

[0008]

【発明の実施の形態】以下、添付の図面を参照して本発明の一実施形態を説明する。

【0009】本発明の実施形態はコンピュータのハードウェアで実施され得るが、以下に説明する実施形態は、例えばパーソナルコンピュータ、ワークステーション、複写機、ファクシミリ等の装置の処理ハードウェアとともに動作するソフトウェアにおいても用いられ得るものである。

【0010】図1は、本発明の一実施形態を処理するよ うに構成されたパーソナルコンピュータ(PC)1を示 す。キーボード3、ポインティングデバイス5、マイク ロフォン7および電話線9は、インタフェース11を介 して接続される。キーボード3およびポインティングデ バイス5によって、ユーザはシステムを制御できる。マ イクロフォン7は、ユーザの音響的音声信号をそれに相 当する電気信号に変換し、この電気信号をPC1に処理 のために供給する。本実施形態において、処理されるべ き入力音声の始点および終点は、入力発声音が継続され ている間キーボード3上のスペースバーを押すことによ って認識される。このような方法で、システムは認識さ れるべき入力発声音を処理する。内蔵モデムおよび音声 受信回路(図示されていない)は電話線9に接続され、 PC1は、例えば遠隔地のコンピュータまたはユーザと 通信することができる。

【0011】本発明で規定するようにPC1を動作させるためのプログラム命令は、既存のPCで用いるために磁気ディスク13のような記憶装置上に供給されてもよいし、または電話線9を介してリモートコンピュータと通信する内蔵モデムによって供給されてもよい。

【0012】本実施形態の限定された語彙による連続音 声認識システムの処理を、図2を参照して説明する。例 えば、マイクロフォン7からの入力音声を示す電気信号 は、プリプロセッサ (PREPROCESSOR) 15に入力され る。プリプロセッサ15は、入力音声信号をパラメータ フレームのシーケンスに変換する。ここで、各パラメー タフレームは、入力音声信号に対応する時間フレームを 示すものである。次に、パラメータフレームのシーケン スは、認識ブロック(RECOGNITION)17に供給され る。認識ブロック17において、入力されたパラメータ フレームのシーケンスを標準モデル即ちワードモデル (WORD MODELS) 19と比較することによって、入力音 声が認識される。標準モデル、即ちワードモデル19の 各モデルは、認識されるべき入力音声と同様の種類のパ ラメータで表されるパラメータフレームのシーケンスで 構成されている。

【 O O 1 3 】言語モデル (LANGUAGE MODEL) 2 1 および

ノイズモデル(NOISE MODEL)23も認識プロック17 に対する入力として供給され、認識プロセスにおいて用いられる。本実施形態において、ノイズモデルは沈黙またはバックグラウンドのノイズを示し、認識されるべき入力音声信号のパラメータフレームと同様のタイプの1つのパラメータフレームから構成される。言語モデル21が用いられ、システムに認知されたワードのシーケンスに適応させるように、認識ブロック17から出力されたワードの取り得るシーケンスを制限する。認識ブロック17から出力されたワードシーケンスはコピーされ、例えばワードプロセッシングパッケージ等で用いられる。または、そのワードシーケンスは、オペレータコマンドとして用いられ、PC1の動作を開始したり、中止させたりまたは修正したりする。

【0014】以下、上記の装置に関するより詳細な説明を行う。

【0015】<プリプロセッサ>プリプロセッサ15について図3~図10を参照して説明する。

【0016】プリプロセッサ15の機能は、必要な情報を音声から抽出することにより処理されるべきデータを削減することである。音声分析の技術分野において、音声を前処理する方法は多数知られており、以下に説明する方法は、一実施形態として示されているものである。よって、以下に説明するような方法に限定されると解釈されるべきではない。本実施形態において、プリプロセッサ15は、「フォルマント(formant)」関連情報を抽出するように設計されている。フォルマントとは、ユーザの声道の共振周波数として定義され、声道の変化にしたがって変化する。

【0017】図3は、入力音声信号に対して行われる前処理を示すブロック図である。マイクロフォン7または電話線9からの入力音声S(t)は、フィルタブロック(FILTER)61に供給され、入力音声信号内のあまり重要でない情報を含む周波数を除去する。音声信号の中で、もっとも重要な情報は、4KHz以下の周波数に含まれる。したがって、フィルタブロック61は、4KHzを上回るすべての周波数を除去する。その後、沪過音声信号は、ADコンバータ(ADC)63によって、ディジタルサンプルに変換される。ナイキストサンプリング基準にしたがって、ADC63は、8000回/砂のレートで沪過信号をサンプリングする。本実施形態において、全入力発声音声はディジタルサンプルに変換され、音声信号を処理するための次のステップの前に、バッファ(図示されていない)に記憶される。

【0018】入力音声が抽出された後、入力音声は、分割ブロック(DIVISION INTO FLAMES)65で互いに一部が重なり合う等しい長さのフレームに分割される。入力音声をフレームに分割する理由をより詳細に説明する。上記のとおり、連続的に音声が発せられる間、フォルマント関連情報は連続的に変化し、その変化の割合は、生

理学的抑制によって制限される音声発声器官の動作の割合に直接的に関連する。したがって、変化するフォルマント周波数を追跡するためには、音声信号は短時間の周期または短いフレームで分析されなければならない。この方法は、音声分析の技術分野において、「短時間」音声分析として知られている。短時間分析を行う際、考慮しなければならない点が2つある。すなわち、(i)どのくらいの速度で、時間フレームが音声信号から抽出されなければならないか、(ii)どのくらいの大きさの時間フレームが用いられなければならないか、という2点である。

【0019】第1の考慮に関しては、音声発声器官の動作速度に依存する。すなわち、重要なイベントを見逃さないことを保証するとともに、適当な連続性を保証するようように、フレームは十分に近寄っている必要がある。本実施形態において、1つのフレームは10msecに1回の割合で抽出される。第2の考慮に関しては、フレーム間の音声信号の特性が一定になるような十分に短い時間フレームと、フォルマントを区別するのに十分な周波数を提供するのに十分に長い時間フレームとの間の妥協しうる点で決定される。 本実施形態において、フレームの長さは20msecであり、上記サンプリング速度で、1つのフレームにつき160個のサンプルに相当する。

【0020】これらのフレームを音声サンプルから直接抽出することによって発生させる場合、かなりの周波数のひずみが生じる。したがって、このようなひずみを低減するため、スムーズウィンドウ機能を用いるべきである。ハミング(Hamming)、ハニング(Hanning)、ブラックマン(Blackman)、バートレット(Bartlett)およびカイザー(Kaiser)等のようなウィンドウは多数存在し、何れも適用可能である。これらすべてのウィンドウは、音声分析の当業者に知られている。本実施形態において、ハミングウィンドウが用いられ、これは以下の等式によって表される。

[0021]

【数1】

$$W(n) = 0.54 - 0.46 \cos \left[\frac{2\pi n}{(N_s - 1)} \right] \qquad \cdots (1)$$

【0022】ここで、Nsはウィンドウ内のサンプルの数、すなわち、160個のサンプルを示す。

【0023】図4は、本実施形態において行われる短時間分析処理を詳細に示す図である。フレーム1 (Flame 1)、すなわち、時刻aと時刻bとの間の音声信号に、上記の式(1)で求められるウィンドウ関数が乗算される。さらに、選択されたフレームの速度およびフレームの長さに従って、次のフレームであるフレーム2は、フレーム1の中間、すなわち時刻cから始まる。

【0024】入力音声信号のフレームがいったん抽出されると、ブロック67(DFT67)においてフレーム

の離散フーリエ変換(DFT)の振幅が計算される。す なわち、 | Sk(f) | が計算される。ここで、 f は離散周 波数変数を示す。このプリプロセッサの多くの態様は、 人間の聴覚システムの動作をシミュレートするために設 計されているので、振幅情報のみが必要であり、入力音 声信号の位相に対しては比較的敏感でない。図5は、1 60個のサンプル、すなわちr=0,1,...159 から構成される1つのフレームSk(r)の典型的な音声信 号を示す。高速フーリエ変換(FFT)アルゴリズムを DFTの計算で有効に用いるため、フレームSk(r)内の サンプルの数を2のべき乗まで増加させる必要がある。 これを達成する方法の1つとして、160個のサンプル の後に96個の0を追加し、256個のサンプルを得る ことが挙げられる。この技術は「〇の充填」として知ら れ、音声分析の分野において公知であるので、これ以上 の説明はしない。

【0025】Sk(r)のDFTをコンピュータで演算する場合、計算処理のために、スペクトルの第1の128個のサンプルだけが必要である。なぜならば、音声は実際の信号であり、後半の128個のサンプルは前半の128個のサンプルの鏡像だからである。図6は、図5に示されるフレームSk(r)内の音声信号のDFT | Sk(f) | の振幅の最初の128個のサンプルを示し、最終のサンプルはサンプリング周波数の半分の周波数、すなわち、4KHzの周波数で発生するものとなる。

【0026】上記のとおり、プリプロセッサ15の目的は、データレートを低減し、入力音声信号の特定成分を強調することである。1つのフレームにつき128個のサンプルしか存在しないので、DFTによるデータレートの低減はわずかである。さらにデータレートを低減する方法の1つとして、スペクトルを等しい周波数帯に分割し、各周波数帯内のサンプルを平均化することが挙げられる。すなわち、図6に示されるサンプルをフィルタバンクに通過させることである。

【0027】人間の聴覚システムに関する研究によれば、耳の周波数分解能が周波数が増加するとともに減少することが示されている。従って、高周波数領域と比較して低周波数領域の中に多くの周波数帯を有するフィルタバンク、すなわち対数スペースフィルタバンクは、直線スペースフィルタバンクよりも好ましい。なぜなら、対数スペースフィルタバンクの方が知覚的に重要な情報をより多く保持することができるからである。

【0028】本実施形態において、40個の周波数帯を有するメルスペースフィルタバンク(MEL FILTER BAN K)69が用いられる。メルスケールは音声分析の分野で公知であり、音声の知覚周波数を線形スケール上にマップしようとする対数スケールである。図7は、メルスペースフィルタバンク69の出力 | S+k(f') | を示し、図6に示されるサンプルがバンク69を通過したときの出力を示す。振幅スペクトルの結果エンベロープ100

は、フィルタバンク69の平均化効果のためにかなりなめらかであるが、フィルタバンクの対数スペースのため に低周波数帯ではなめらかではない。

【0029】次に、フォルマント関連情報が、図3のブロック71、73および75を用いて、下記のプロセスによって音声から抽出される。

【0030】励起信号E(t)およびフィルタV(t)の項を用いて、ユーザの音声信号S(t)をモデルにすることができる。ここで、励起信号E(t)は声道に入る空気流を示し、フィルタV(t)は声道の沪過効果を示す。結果的に、音声信号の周波数スペクトル |S(f)| の振幅は、励起信号の周波数スペクトル |E(f)| の振幅と声道フィルタのスペクトル |V(f)| の振幅を乗算することによって求められる。すなわち、以下の(2)式によって求められる。

[0031]

【数2】

$$|S(f)| = |E(f)| \cdot |V(f)| \cdots (2)$$

【0032】ケプストラム法(cepstral method)として知られる方法、すなわち、音域情報を入力音声から抽出する方法の一つを以下に示す。この方法は、音声振幅応答 |S(f)| の対数を取ることによって、音域フィルタ振幅応答 |V(f)| を励起振幅応答 |E(f)| から分離することを含む。この結果、励起および声道フィルタの特性の和で表わされるようになる。すなわち、(3)式によって求められる。

[0033]

【数3】

$$\log |S(f)| = \log |e(f)| + \log |V(f)| \qquad \cdots (3)$$

【0034】図8は、メルフィルタバンク69からのログ出力のエンベロープ、すなわち、 $log \mid Slk(f') \mid e$ を示し、2つの成分101および103の加算性を図示するものである。成分101は、声道特性、すなわち、 $log \mid V(f) \mid e$ 示す。成分103は、励起特性、すなわち、 $log \mid E(f) \mid e$ 示す。成分101のピークは、声道のフォルマント周波数で発生する。また、成分103の等間隔のピークは、話者のピッチのハーモニック周波数で発生する。

【0035】声道特性101は、ブロック(LOG)7 1から出力されたサンプルに離散コサイン変換(DC T)を行い、その結果をフィルタリングすることによって、励起特性103から抽出できる。

【0036】図9は、DCTブロック73の出力を示す。これは、ケプストラム (cepstrum) Ck(m)として知られている。ケプストラムの独立変数 (図9のx軸) は時間の次元を有し、「クエフレンシ (quefrency)」と名づけられている。図8に示される強い周期性を有する成分103は、話者のピッチ周期Tに等しい位置で、ケプストラムのピーク105になる。また、図8に示され

るゆっくり変化する成分101は、ケプストラムの原点 付近の多数の小さいピーク10に変換され、その位置お よび振幅はフォルマントに依存する。

【0037】音声の声道特性および励起特性がクエフレンシスケール上の分離した部分にあらわれるので、これらは、沪過プロセスまたはケプストラム用語で言ういわゆる「リフタリング(liftering)」プロセスによって、互いに分離される。図9に示されるケプストラムCk(m)は、1組の離散ケプストラム係数(discrete cepstral coefficient)(CO,C1,...C39)から構成される。したがって、リフタリングは、1つの矩形ウィンドウによって達成されうる。しかしながら、信頼性が劣ると考えられるスペクトルの部分を強調しないようにするため、より漸次的なウィンドウ機能が好ましい。本実施形態において、以下のウィンドウ機能が、リフタリングブロック(LIFTERING)75で用いられる。

[0038]

【数4】

$$W_{lift}(m) = 1 + \frac{N_c}{2} \sin \frac{\pi m}{N_c} \qquad \cdots (4)$$

【0039】ここで、Ncは、リフタリングブロック75から各フレーム毎に出力されたケプストラム係数の所望の個数であり、本実施形態では12である。

【0040】また、上記の12個のケプストラム係数に 加えて、各フレーム内の音声信号のパワー、すなわち、 「フレームパワー」もまた計算される。これは、フレー ム内の入力音声信号が発生音声信号に対応するか否かを 示すのに用いられるので、とりわけ重要な特徴である。 フレームパワーは、音声分析の分野では公知の一般的な 方法を用いて、図3に示されるフレームパワーブロック (FRAME POWER) 81で計算される。変化しうる記録環 境や音の大きさ等に影響されないように、ブロック81 で決定されたパワーは、パワー正規化ブロック(POWER NORMALIZING) 83で正規化され、パワー係数Pkを求め る。パワー係数Pkは、リフタリングブロック75から出 力されたケプストラム係数に結合される。パワーは、バ ッファ(図示されていない)に記憶された発声音全域に わたって最大パワー(d B)を決定し、これを各フレー ムのパワーから減じ、その結果と正規化定数とを掛ける ことによって、ブロック83で正規化される。

【0041】本実施形態においては、各フレーム内の入力音声信号のパワーが決定されるが、各フレーム内の入力音声信号を示す他の値も用いられる。例えば、フレーム内の入力音声信号の平均振幅の尺度が決定され、正規化され得る。

【0042】以上のように、プリプロセッサ15は、各時間フレームで、1組の係数、すなわち、12個のケプストラム係数および1つのパワー係数を出力する。便宜上、フレームkを示す係数は、パラメータフレームfkとして示され、次のフレームを示す係数は、パラメータ

フレーム f k+1等として示す。

【0043】<バッファ>プリプロセッサ15から出力されたパラメータフレームfkは、図2に示されるバッファ(BUFFER)16に供給される。本実施形態において、バッファ16は、ADC63から出力された入力音声のディジタルサンプルを記憶するバッファ(図示されていない)に記憶された音声に関して生成されたすべてのパラメータフレームを記憶するのに十分な容量を有する。全入力発声音がプリプロセッサ15によって処理された後、バッファ16に記憶されたパラメータフレームは、それらが受信された順番で認識ブロック17に供給され、入力発声音が認識される。

【0044】<標準モデル>上記のとおり、どのワードがプリプロセッサ15からの出力信号によって表現されているかを決定するため、出力信号は記憶されている標準モデルと比較される。この記憶された標準モデルは、システムに既に認知されたワードおよびシステム周辺の音響環境をモデルにしたものである。特定のワードに関連する各モデルは、上記プリプロセッサ15から出力されたパラメータフレームと同じタイプのパラメータフレームのシーケンスで構成される。しかしながら、ワードモデルのフレームと認識されるべき入力発声音のフレームとを区別するため、ワードモデルのフレームはステート(state)と表現することにする。

【0045】本実施形態による音声認識システムの1つ の特徴は、ワードモデル、環境(または、ノイズ)モデ ルまたは言語モデルがシステムに前もって記憶されてい ないエンドユーザに供給され得ることである。これによ って、ユーザは自由にシステムを学習させ、ユーザが必 要とするフレーズを認識させるようにすることができ る。さらに、ユーザにとって有用でないワードが予め記 憶されていることで、システムが過負荷となることを防 止できる。さらに、以下の記載から明らかなように、記 載された特定の学習方法はこの状況において特に適して いる。なぜならば、それは、学習のために費やされる時 間を必要とせずに新しいフレーズがシステムによって学 習されることを可能とするからである。さらに、標準モ デルは、すべてのワードに対応し、音素には対応しない ので、システムは、いかなる言語または言語の組み合わ せに対しても動作する。学習プロセスを、図10から図 17を参照してより詳細に説明する。

【0046】<学習>図10は、学習プロセスで用いられる構築/更新モジュール(BUILD/UPDATE MODULE)91を示す概略図である。特に、構築/更新モジュール91は、システムによって学習されるべき1つ以上のワードを示すパラメータフレームfkのシーケンスと、矢印92で示される1つ以上の入力音声ワードに対応するテキストを示すユーザ情報とを受ける。十分な情報が構築/更新モジュール91に入力されると、入力ワードに対応するワードモデルを発生し、言語モデル21を更新す

る。本実施形態において、ワードモデルおよび言語モデルの両方は、ハードディスク93のような高容量のデータ記憶装置に記憶される。

【0047】ノイズモデル23が本実施形態において決 定される方法を以下に説明する。まず、ユーザは新しい ノイズモデルを構築したり、または既存のノイズモデル 23を変化させる必要があることを指示する。この指示 に応じて、システムは、ユーザに沈黙を示す音を入力す るよう促す。この処理は、沈黙状態の間、ユーザがキー ボード3上のスペースバーを押すことによって行われ る。沈黙の周期の終わりには、ユーザはワードを発生し なければならない。システムが沈黙を示すべく生成され たパラメータフレームのパワー係数を正規化できるよう にするためである。ユーザが沈黙の周期の終わりにワー ドを発声しない場合、ノイズモデル23のパワー係数が 非現実的に高くなり、非認識エラーが生じることにな る。最後に、ノイズモデル23を決定するため、システ ムは沈黙の期間に対して生成されたパラメータフレーム を平均化し、ノイズモデル23として用いられる1つの パラメータフレームを形成する。

【0048】本実施形態の音声認識システムは、連続的 に発声されるワード、すなわち、フレーズ内に含まれる ワードを認識するために設計されている。良い認識結果 を得るため、標準モデル(または、連続ワードモデル) は、重要なワードを含むフレーズ例から得るべきであ る。好ましくないことに、連続的に発声されたフレーズ 内のワードの始めと終わりを確認する作業は容易ではな い。本実施形態が連続ワードモデルを発生させる方法の 概略を以下に示す。まず、システムは、分離的に発声さ れたワードからワードモデルを決定する。このモデル は、分離ワードモデルとして示す。しかし、音声認識の 当業者が以下の記載から理解するように、これらの分離 ワードモデルは、本技術分野における一般的な分離モデ ルには相当しない。システムは分離ワードモデルを用 い、分離ワードモデルとそれに相当するワードを含むフ レーズ例とを比較することによって、連続ワードモデル を生成する。

【0049】分離ワードモデルを生成するため、ワードは、マイクロフォン7または電話線を介して分離的にシステムに入力されなければならない。上記のとおり、スペースバーが用いられ、各入力発声音を確認する。したがって、分離的に発声されたワードの発声音を示すパラメータフレームのシーケンスは、沈黙に対応するパラメータフレームをワードの始めと終わりに有する。次にシステムは、分離ワードの発声音と当該ワードを含むフレーズ例とを比較する。この比較によって、分離的発声音内のワードのおよその始めと終わりを確認する。この始点と終点は平均化され、そのワードに対する分離ワードモデルは、確認された始点と終点との間にある平均化されたパラメータフレームのシーケンスを抽出することに

よって、決定される。この方法で分離ワードモデルを決 定することによって、ワードの始めと終わりの沈黙を除 去するだけではなく、そのワードの部分であって、連続 的な発声音声の間において発音されない部分も除去され る。したがって、本実施形態の分離ワードモデルは一般 的な分離的ワードモデルには対応せず、沈黙を入力発声 音の始めと終わりから除去することによって決定され、 連続音声が発せられているときのワードをより適切に表 すものとなる。

【0050】いったん分離ワードモデルが決定されると、フレーズ内の当該ワードの位置を確認するために、当該ワードを含むフレーズ例と整合される。最後に、標準ワードモデルまたは連続ワードモデルは、フレーズにおける確認位置からの音声を抽出及び結合することによって、決定される。システムがワードモデルを生成する方法の詳細について、以下に説明する。

【0051】ユーザがシステムに1つ以上の新しいフレ ーズを教えたい場合、図11に示されるサブルーチンを 起動する。ステップS1で、ユーザは、新しいワードま たはフレーズのテキストをキーボード3を介してシステ ムに入力する。システムは、ステップS3において、そ のワードまたはフレーズが既知のものであるか否かをチ ェックし、そのワードまたはフレーズが未知のものであ れば同じワードまたはフレーズをマイクロフォン7を介 して入力するようユーザに促す。そして、ステップS1 に入力されたワードまたはフレーズに対応するテキスト に、マイクロフォン7を介して入力されたフレーズを関 連させる。次にステップS5において、PC1は、前も って入力されていたすべてのテキストを用い、フレーズ 内のどのワードが(分離された状態で)既知となってい るかをチェックし、未入力(未知)のワードをマイクロ フォン7を介して入力するようユーザに促す。

【0052】ステップS5の後、ユーザは、ステップS 7にて他の新しいワードまたはフレーズを入力するかど うかを決定する。新たに入力する場合は、ステップS1 に戻る。他方、ユーザがこれ以上ワードを入力しないこ とを決定した場合、処理はステップS9に移動する。ス テップS9において、標準モデルは、システムに入力さ れた少なくとも2つのフレーズに含まれる未知ワードに ついて生成される。例えば、学習フレーズが入力されて おらず、システムには標準モデルがまだ記憶されていな い状態で、ユーザが「get an image (画像を得る)」お よび「get theearth (接地する)」という2つのフレー ズを入力し、ステップS7でユーザがこれ以上フレーズ を入力する意志がないことを指示した場合を説明する。 この場合、入力フレーズの両方に含まれるワードは「ge t(得る)」の1つだけなので、システムは「get」とい うワードのワードモデルを生成するだけでよい。他方、 ユーザが「get an image (画像を得る)」というフレー ズを2回入力する場合、システムは、当該フレーズ内の 各ワードの標準モデルを生成させ得る。さらに、上記の前者の例を取れば、ユーザが「get an image (画像を得る)」および「get the earth (接地する)」という2つのフレーズを入力した後、第2の学習セッションで「get the earth (接地する)」というフレーズを入力した場合、「get (得る)」というワードは既に分離して入力されているので、システムは、ステップS5で「get (得る)」というワードを入力する必要がないことをユーザに伝える。さらに、「the (その)」及び「アース (earth)」というワードはシステムに入力されている2つのフレーズによって表されるので、システムは「the (その)」及び「アース (earth)」というワードの標準モデルを発生させることができる。この方法で学習を進めることにより、ユーザはシステムをユーザにとって都合よく学習させることができる。

【0053】図12を参照すると、上記方法で入力され た各フレーズは、フレーズ番号Pを付され、ハードディ スク93のフレーズアレー115に記憶される。同様 に、入力される各分離ワードにはワード番号Wが付さ れ、ハードディスク93のワードアレー117に記憶さ れる。図12に示されるように、フレーズアレー115 内の各フレーズPは、自身に関連する次のようなデータ を有する。すなわち、パラメータフレーム (PARAMETER) FRAMES) 123、フレーズを形成するワードシーケンス (PHRASE WORDS) 125およびステータスフラグ (STAT US) 127を有する。ワードシーケンス125内の各ワ ードは、自身に関連するテキスト(TEXT)129、フレ ーズ番号P、ワード番号 (WORD No.) 131 (すなわ) ち、フレーズ内のワードの位置)、フレーズ内のワード の(最初は認知されていない)時間境界(TIME BOUNDRI ES) 133、およびワードアレー117内の対応するワ ードWを示すワードインデックス(WORD INDEX)135 を有する。

【0054】ワードアレー117内の各分離ワードWは、自身に関連する次のようなデータを有する。すなわち、パラメータフレーム(PARAMETER FRAMES)137、当該ワードが見出されたフレーズへの戻りを示す発声音インデックス(UTTERANCE INDEX)139およびステータスフラグ(STATUS)141を有する。まず、分離ワードおよび分離フレーズがシステムに入力されると、各ワードまたはフレーズに関連するステータスフラグ127および141は、それらがまだ処理されていないことを示すFLEXIにセットされる。なお、時間境界133は、フレーズのワードシーケンス内の各ワード毎に存在し、UNKNOWN(未知)に設定される。

【0055】次に、図11のステップS9で行われる未 知ワードのワードモデルを生成するための処理の詳細を 図12から図16を参照して説明する。ここでは、学習 フレーズとして「get an image (画像を得る)」という フレーズが2回、「get theearth (接地する)」という フレーズが1回入力された場合を例として用いて説明する。したがって、フレーズアレー115には3つの要素 P1、P2およびP3が存在し、「get an image (画像を得る)」という発声音声のフレーズが2つと「get the earth (接地する)」という発声音声のフレーズが1つ含まれる。さらに、ワードアレー117には5つの要素W1、W2、W3、W4、W5があり、上記2種類のフレーズを構成するそれぞれ異なるワードが1つずつ含まれる。上記のとおり、各フレーズおよび異なる各ワードに対応するパラメータフレームのシーケンスは、フレーズアレー115およびワードアレー117の各対応する要素毎に記憶される。

【0056】図13には、2つの「get an image (画像 を得る)」のフレーズの発声音を示す音声信号151お よび153と、「get the earth (接地する)」のフレ ーズの発声音を示す音声信号155とが示されている。 また、図13には、「get (得る)」、「an (1つ) の)」および「image (画像)」という各ワードの分離 的発声音を示す発声信号157、159および161も 示されている。更に、図13には、「get an image (画 像を得る)」の2つのフレーズの発声音に相当するパラ メータフレーム152および154と、「get the eart h(接地する)」のフレーズの発声音に相当するパラメ ータフレーム156と、「得る(get)」、「1つの(a n)」および「画像(image)」という各分離ワードの発 声音に相当するパラメータフレーム158、160、1 62も示す。なお、「the (その)」および「earth (接 地)」というワードについては、それらが入力された2 つ以上のフレーズに含まれていないためワードモデルは 生成されない。従って、これら、「その(the)」およ び「接地(earth)」というワードは、図13には示さ れていない。

【0057】図14は、各未知ワードのワードモデルを 生成するために必要な処理を詳細に示すフローチャート である。ステップS21で、未知ワードを含むフレーズ に対応するパラメータフレームシーケンスが、分離して 発声された当該未知ワードに対応するパラメータフレー ムシーケンスと関連付けられる。この関連付け処理に は、フレキシブルダイナミックプログラミングアライン メント処理が用いられる。このアラインメント処理は、 そのプロセスの初期段階における未知ワードの始点と終 点に関する情報の欠乏を緩和する、特に、各ワードの最 適アラインメントパスが始まらなければならない場所或 いは終わらなければならない場所を制限しないフレキシ ブルダイナミックプログラミングアラインメントプロセ スが用いられる。このフレキシブルダイナミックアライ ンメントプロセスについては、ダイナミックプログラミ ングアラインメントについて論じた後に、詳細に後述す る。

【0058】このフレキシブルダイナミックプログラミ

ングアラインメントの結果、未知ワードに対するパラメータフレームシーケンス内の当該未知ワードのおよその始点および終点が特定される。例えば、「get an image(画像を得る)」というフレーズの第1の発声音に相当するパラメータフレームシーケンス158に関連付けられるとき、パラメータフレームシーケンス158に関連付けられるとき、パラメータフレームシーケンス158内の始点および終点は上記アラインメントの結果から確認される。上記のとおり、始点前および終点後のパラメータフレームは、バックグラウンドのノイズまたはフレーズ例におけるワードの発音されない部分に相当しているので、除去される。

【0059】ステップS21において、学習フレーズ例 に対して行われるアラインメントでは、「get (得 る)」というワードの3組の始点および終点と(「ge t」というワードは3つのフレーズに含まれているた め)、「an (1つの)」と「image (画像)」のワード の2組の始点および終点と(「an」と「image」のワー ドは、2つのフレーズに示されているので)を確認す る。ステップS23で、それぞれの未知ワードの平均始 点および平均終点が決定され、平均スタートフレームの 前にあるフレームおよび平均エンドフレームの後にある フレームが捨てられる。例えば、「get」というワード をステップS21で処理した後、3つのフレーズ15 1、153、155を用いて確認された始点がそれぞれ フレーム f 8W1、フレーム f 9W1、フレーム f 13W1である 場合、その平均はフレーム f 10W1([8+9+13]/ 3)である。そして、フレーム f 10W1の前にあるパラメ ータフレーム158のシーケンス内のすべてのフレーム は、捨てられる。終点についても、捨てられるフレーム がエンドフレームを越えるものであるという点を除い て、上記した始点の場合と同様の手順が用いられる。そ の結果、各ワードのパラメータフレームシーケンスは、 上記のワードの分離ワードモデルとなる。

【0060】図15は、「get」、「an」、「image」の 各ワードの分離ワードモデル音声信号157'、15 9'、161'、およびそれぞれに対応するパラメータフ レームシーケンス158'、160'、162'を示す。 処理のこの段階で、処理された各ワードのステータスフ ラッグ141(図12)は、FLEXIからCHOPPEDに変わ る。なお、CHOPPEDは、未知ワードが始めと終わりが除 去されたフレームシーケンスを有していることを示す。 【0061】次に、図14に示されるステップS25に おいて、未知ワードを含むフレーズに対応するパラメー タフレームシーケンスは、当該ワードの分離ワードモデ ルのパラメータフレームシーケンスに関連付けられる。 例えば、「get」というワードが出現するフレーズの発 声音に対応するパラメータフレームシーケンス152、 154、156の各シーケンスと、「get」というワー ドの分離ワードモデル158'に対応するパラメータフ レームシーケンスとの整合がチェックされる。図16は、本例を行った対応付け(アラインメント)の結果を示し、ここで破線は、フレーム間のアラインメントを示す。例えば、パラメータフレームシーケンス152と分離ワードモデルのパラメータフレームシーケンス158'とのパラメータフレームのシーケンスとの間のアラインメントでは、フレームf2P1およびf3P1がフレームf10W1に関連付けられ、フレームf4P1およびf5P1がフレームf11W1に関連付けられる等、アラインメントが確立されている。

【0062】次に、図14のステップS27において、 分離ワードモデルの個々のフレームを、フレーズに対応 するパラメータフレームのシーケンスからの関連フレー ムの平均で置き換えることによって未知ワードの標準モ デルが生成される。例えば、図16に示される分離ワー ドモデル158'のパラメータフレームシーケンスにお いて、フレームf10W1は、フレームf2P1、f3P1、f 1P2、 f 2P3の平均に置き換えられる。また、フレーム f11W1は、フレームf4P1、f5P1、f2P2、f3P2、f 3P3の平均に置き換えられる。分離ワードモデルのフレ ームの1つに関連付けられるフレームがフレーズに存在 しない場合、そのフレームは、隣接する置き換えられた フレームの間を捕聞するかまたはフレームから外挿する ことによって得られるフレームに置き換えられる。例え ば、図16に示されるパラメータフレーム158'のシ ーケンスにおいて、フレーム f 12W1は、パラメータフレ ームシーケンス152、154または156内のいずれ のフレームにも関連付けられない。従って、f12W1は、 f 11W1、f 13W1の置換後のフレームで捕間することに よって得られたフレームに置き換えられる。或いは、分 離ワードモデル内における、入力フレーズのいずれのフ レームにも関連しないフレームを捨てるように構成して も良い。

【0063】ステップS27で生成された基準ワードモデルは、システムの音声認識部で用いられるものであり、その詳細を以下に示す。なお、処理された各ワードのステータスフラグ141は、CHOPPEDからIN-USEに変化する。

【0064】いったん標準ワードモデルがフレーズ内のすべてのワードについて生成されると、フレーズは、図2に示される言語モデル21に追加される。本実施形態において、言語モデル21は、バイグラムモデル(Bigram Model)と同様で、網目上に相互に接続するノードを備える。ここで、相互接続は、システムに既知となったワードを示す。しかしながら、この相互接続には、例えば、正しい英語の用法に関する文法規則は含まれていない。すなわち、システムに認知されたフレーズに従って、どのワードが他のどのワードに続くかを制限するだけである。図17 aは、以下の各フレーズがシステムによって学習されたときに取り出される言語モデル21を

示す。

[0065]

【表1】

get an image	- phrase 1
get the earth	- phrase 2
get the fjord	- phrase 3
get the map	- phrase 4
get the coin	- phrase 5
-save an image	- phrase 6
load an image	- phrase 7
make it smaller	- phrase 8
make it larger	- phrase 9
make it brighter	- phrase 10
make it more red	- phrase 11
make it more yellow	- phrase 12
make it more green	- phrase 13
make it more cyan	- phrase 14
make it more blue	- phrase 15
make it more magenta	- phrase 16
quit	- phrase 17

【0066】図17aに示されるように、スタートノー ドNO、エンドノードNn、8個の中間ノードN1からN8 がある。認識されるべき入力フレーズのために、システ ムは、スタートノードN0からエンドノードNnまでのパ スを見つけなければならない。しかしながら、システム は一度学習されると妥当な程度にフレキシブルになり、 ユーザが「make it smaller」というフレーズの代わり に「make smaller」と入力しても、システムはその入力 されたフレーズを認識することができる。しかしなが ら、フレーズの個々のワードが既知であっても、そのフ レーズがシステムに認知されていない場合、システムは フレーズを認識しない。例えば、上記の言語モデルにお いて、ユーザが「save the image」と言った場合、たと えシステムにとって「save」、「the」、「image」の各 ワードが既知であっても、システムはこの入力フレーズ (「save the image」) を認識しない。

【0067】言語モデル21は、図11のステップS3で入力されたテキストによって示される必要なワードのシーケンスを抽出することによって作成され、各新しいフレーズが入力された後に更新され、フレーズ内の各ワードにはワードモデルが提供される。言語モデル21を更新する方法について、図17bを参照して以下に説明する。

【0068】新しいフレーズが入力され、入力フレーズ の各ワードに対応するワードモデルが決定されると、ス テップS30においてシステムは、フレーズの第1のワ ードがスタートノードN0の出力に接続されているかどうかを判断する。接続されている場合、処理はステップS32に進む。他方、第1のワードがスタートノードN0の出力にまだ接続されていない場合は、ステップS31でスタートノードN0からの新しい出力として第1のワードが追加される。

【0069】処理はステップS32に進み、ここでシス テムはワードループカウンタwを初期化する。以降の処 理で、システムは、このワードループカウンタwを用い て、当該フレーズ内の全ワードを数える。処理はステッ プS33に進み、ここでシステムはワードwが当該フレ ーズの最後のワードか否かを判断する。ワードwが最後 のワードでない場合、処理はステップS34に進み、ワ ードwがノード(エンドノードNnを除いた)の入力に 接続されているか否かを判断する。接続されていれば処 理はステップS36に進み、ここでシステムは、次のワ ードw+1がワードwを入力として有するノードの出力 に接続されているかどうかをチェックする。他方、ステ ップS34で、ワードwがいずれのノードの入力にも接 続されていないとシステムが判断した場合、処理はステ ップS35に進み、ここで新しいノードが作成され、ワ ードwは、新しいノードの入力に接続される。それか ら、上記のとおり、処理はステップS36に進む。

【0070】ステップS36で、次のワードw+1がワ ードwを入力として有するノードの出力に接続されてい ないとシステムが判断した場合、処理はステップS37 に進む。ステップS37では、次のワードw+1が当該 ノードの出力として追加される。一方、ステップS36 で、次のワードw+1が既にワードwを入力として有す るノードの出力に接続されているとシステムが判断した 場合は、そのままステップS38に進み、ここでワード カウンタwがインクリメントされる。そして、処理はス テップS33に戻り、入力フレーズの次のワードに対し て同様の処理が行われる。また、ステップS33で、ワ ードwがフレーズの最後のワードであることを判定され た場合、処理はステップS39に進む。ステップS39 において、システムは、最後のワードがエンドノードN nの入力に接続されているか否かを判断する。最後のワ ードがエンドノードNnの入力に接続されていない場 合、処理はステップS40に進み、ここでシステムは、 フレーズの最後のワードをエンドノードNnの入力に接 続する。最後のワードがエンドノードNnに既に接続さ れているか、またはステップS40で最後のワードがエ ンドノードNnに接続されると、本処理を完了し、処理 された入力フレーズは言語モデル21の一部を形成する ことになる。

【0071】本学習プロセスの特徴の1つは、システムに個々にフレーズを学習させることもできるし、一度に多数のフレーズを学習させることもできる。新しいフレーズが入力され、この時点でシステムが既にフレーズ内

のいくつかのワードのワードモデルを有する場合、システムは言語モデル21を更新する前に、当該フレーズの未知ワードについてワードモデルを生成する必要がある。

【0072】<ダイナミックプログラミング(DP)> 図14のステップS21およびS25で行われる処理において、フレーズのパラメータフレームとワードのパラメータフレームとを関連付けるために、アラインメント処理が用いられた。より効果的な方法で2つのシーケンスを関連させるため、アラインメントプロセスは、例えば、ワードが分離して発せられたり、ワードが連続的に発せられるフレーズに含まれる場合に生じるワードの発声速度の差を補償することが要求される。上記のダイナミックプログラミング(DP)のアラインメントプロセスは、あるワードを別のワードに合致させる一つの方法である。これは、最適な非線形の時間スケールのひずみを適用して、すべての時点で最適にマッチさせる方法で行われる。

【0073】DPマッチングプロセスの概略を、図18から図20を参照して以下に説明する。図18は、横座標方向に入力ワードを示すパラメータフレームのシーケンスを示し、縦座標方向にワードモデルを示すパラメータフレームのシーケンスを示す。本例を図14のステップS25で行われる処理と比較すると、入力ワードを示すパラメータフレームは、入力フレーズの1つに相当するパラメータフレームシーケンスの一部分を示す。また、ワードモデルを示すパラメータフレームシーケンスは、切り出されたワードの1つに相当するフレームシーケンスを示す。

【0074】ワードモデルと入力ワードとのトータル的な違いを見つけるため、図18の左下隅と右上隅との間のあらゆるパスに沿って最短累積距離が得られる数対のフレームに関してすべての距離の和を求める必要がある。この限定は、類似するワードの対応するフレームが正しく関連付けられることを保証する。このような総距離を計算する1つの方法は、すべてのありうるパスを考慮し、各パスに沿った各点のd(k,j)の値(フレームkとフレーム」との間の距離)を加算することである。2つのワードの間で評価された距離の最小値を取り、累積距離を求める。この方法は正しい答えを与えるが、有効パスの数が増加するので、実用的な音声認識システムのためのコンピュータ処理は不可能となる。

【0075】ダイナミックプログラミングは数学的技術であり、すべての取り得るパスの距離を計算することは行わずに、最適なパスの累積距離を求めることができる。累積距離が計算されるべきパスの数は、さらにDPプロセスを制限することによって、低減される。例えば、最適パスは負の傾斜にはなり得ない。負方向の傾斜に進む場合、ワードの1つは他のワードの時間を逆にさかのぼる状態になる。DPプロセスに対するもう1つの

制限は、基準ワードに対する入力ワードの時間圧縮/拡 張の最大量を制限することである。本実施形態におい て、この制限は、マッチングプロセスで飛ばされたりま たは繰り返されるフレームの数を制限することによっ て、実現される。例えば、図19において、フレームシ ーケンスは、フレームfkがフレームfjmに合致する場 合、フレームfk+1がフレームfjm、fj+1m、fj+2mま たはfj+3mに合致するように制限される。したがって、 入力ワードのフレーム f kおよびワードモデルのフレー ムfjmが最適パス上にある場合、上記制限において、最 適パス上で直ちに処理する点は、図20に示すように、 (k-1, j), (k-1, j-1), (k-1, j-1)2) (k-1, j-3) のいずれかである。

【0076】図18は、フレームfk-1まで伝わる「有 効パス」を示し、入力ワードとワードモデルとの間のマ ッチング候補を示す。フレームfkが認識ブロック17 に入力されるとき、各有効パスは、現フレームfkと有 効パスの最後にあるワードモデルのフレームとの間の局 部距離を有する。この局部距離は累積距離に追加される べきものである。多数のパスが同じ点で出会う場合、最 短の累積距離の有効パスが継続され、他のパスは捨てら れる。例えば、図18で、パスA、B、Cは点(k, j)で出会うが、最短累積距離を有するパス(A、Bま たはCのいずれか) は継続され、その他の2つのパスは 捨てられる。

 ${\tt IOO77}$ したがって、 ${\tt D(k,j)}$ を、ワードの始 めから点(k,j)までの有効パスに沿った累積距離と

[0078]

【数5】

$$D(k,j) = \sum_{\substack{x,y=1\\\text{along } a\\\text{valid path}}}^{k,j} d(x,y) \qquad \cdots (5)$$

【0079】で表される。

【0080】また、上述した制限は以下のとおりであ る。すなわち、

[0081]

【数6】

$$D(k, j) = d(k, j) + \min[D(k-1, j), D(k-1, j-1),$$

D(k-1, j-2), D(k-1, j-3) ...(6)

【0082】となる。

【0083】上記制限で、D(0,0)の値は、d (0,0),d(1,0),d(2,0) schidd (3,0)と等しくなければならず、すべてのパスはこ れらの点のうちの1つから始まらなければならない。し たがって、始点の1つから始め、D(k,j)の値は、 帰納的な処理ルーチンを介して決定され得る。ルーチン がマッチングされるべきワードの終わりに到達すると、 DPプロセスによって計算された最小累積距離は、2つ のワードをマッチさせる最適なパスのスコアを示す。認 識されるべき入力発声音がワードシーケンスから構成さ れる場合、採用された方向を示すバックポインタが用い られなければならない。DPプロセスが最適のパスの終 わりを示した後、そのバックポインタで戻りながら跡を たどることによって、入力発声音を認識することができ るようにするためである。

【0084】上記のDPプロセスは、すべてのパスを網 羅して探索することと比較して、大幅にコンピュータ処 理の付加を低減するが、各入力ワードとのマッチングを 行うために多数のワードモデルと比較しなければならな い場合、他のコンピュータ処理も重要となり得る。した がって、認識結果の精度に大した影響を及ぼさないコン ピュータ処理を省略することは望ましい。可能なコンピ ュータ処理の省略は、スコアの悪いパスが必要以上に形 成されることを防ぐことである。成長するパスが木の枝 に似ているので、この処理は「刈り込み (pruning)」 として知られている。このようにパスの刈り込みによっ て、最適パスの両側の候補パスを含むパスの狭帯のみが 考慮される。このような借り込みが用いられる部分で は、ダイナミックプログラミングプロセスが最適のパス を確実に見つけるとは限らないことが認められる。しか しながら、刈り込みしきい値を用いて、例えば5~10 の要因でコンピュータ処理の平均量を低減し、ワードが よく類似する場合であれば殆ど常時正しいパスが求めら れる。

【0085】なお、本実施形態において、図2に示され

る認識ブロック17は、上記と同様のダイナミックプロ

グラミングマッチングプロセスを用い、ワードモデル1 9およびノイズモデル23で認識されるべき発声音のパ ラメータフレームのシーケンスのマッチングを行う。 【0086】<認識検索>本実施形態による音声認識シ ステムのもう1つの特徴は、ダイナミックプログラミン グプロセスが行われる方法にある。特に、本実施形態 は、上記等式(6)で行われた最小値の計算、すなわ ち、以下の式(7)が処理される現フレーム f kに影響 されないことを利用する。したがって、前フレーム fk-1が処理されるとき、等式(6)のこの部分が計算され

[0087]

【数7】

 $\min[D(k-1,j), D(k-1,j-1), D(k-1,j-2), D(k-1,j-3)]$ \cdots (7)

【0089】図21は、認識すべき入力発声音を入力し

【0088】ダイナミックプログラミングプロセスを実 施する方法を、図21~図31を参照して以下に説明す

た際に、認識ブロック17で行われる処理を示すフロー チャートである。システムは、プリプロセッサ15によ って生成された入力発声音のパラメータフレームシーケ ンスを処理する。フレームカウンタ変数kはこの処理に 供され、変数kは、ステップS41で0に初期化され、 各フレームが処理される毎にステップS61で順次イン クリメントされる。処理される各フレームは、ステップ S47で用いられ、各ワードモデル内の他の有効パスの 累積距離を更新する。ワードカウンタwはこの処理に供 され、ステップS43で0に初期化され、ステップS4 7の後、ステップS49でインクリメントされる。 ステ ップS45で、システムは、現フレームを用いて、すべ てのワードモデルが処理されたかどうかをチェックす る。すなわち、システムは、ワードカウンタwがシステ ムに認識されたワードの数nwを下回るかどうかをチェ ックする。

【0090】現フレームfkを用いて、全ワードモデルがいったん処理されると、処理はステップS51に進み、ここで図17aに示される言語モデル21のノードが、現フレームを用いて処理される。ステップS51で行われる処理は、現パラメータフレームが、入力音声の始めと終わりまたは入力音声の許されたワードシーケンス間の沈黙に対応するという状況を処理する。また、この処理は、有効パスが、許容されたワードシーケンスの範囲に沿って成長するのを保証する。

【0091】ステップS51でノードが処理された後、各ワードモデルの始め、即ち「エントリステート」の1つで終わる有効パスの累積距離がステップS57で更新される。この処理は、現パラメータフレームfkがあるワードモデルの終わりにマッチングするときに、次のパラメータフレームfk+1が他のワードモデルの始めに合致するという状況に対処する。これを達成するため、ワードカウンタwは、ステップS53で再度初期化される。ステップS55でシステムは、すべてのワードモデルが処理されているかどうかをチェックする。ステップS57でシステムは、現ワードモデルのエントリステートに対する累積距離を更新し、ワードカウンタwが、ステップS59でインクリメントされる。そして処理は、ステップS55に戻る。

【0092】すべてのワードモデルが現パラメータフレーム fkについて処理された後、パラメータフレームカウンタ変数 kは、ステップS61でインクリメントされる。ステップS63でシステムは、処理されるべき入力発声音がこれ以上存在するかどうかを判断する。これはステップS63で変数 kをシステム限界(LIMIT)及び音声終了識別子(EOS)と比較することによって、この処理は行われる。システム限界は、図3に示されるADC63から出力された音声サンプルを記憶するために用いられるバッファの容量によって決定される。【0093】入力発声音のすべてのパラメータフレーム

が処理された場合、DPプロセスが完了し、回帰アルゴリズムを用いて最適パスを決定し、それによって、認識結果を決定する。他方、ステップS63でシステムが処理されるべきパラメータフレームがさらに存在すると判断された場合、ステップS65でシステムは刈り込みしきい値を調整し、ステップS43に戻る。刈り込みしきい値Thは、次の入力フレームが処理されるとき、ステップS47、S51、S57で処理される有効パスの数を制限するベくステップS65で調整される。

【0094】図21のステップS47で行われる処理の詳細を、ワードモデルの特定の例を示す図22から図26を参照して以下に説明する。図22は、ワードモデル201の一例を示す。特に例示されているワードモデル201は、学習セッションの間に得られたステートS0~S9のシーケンスと、ワードモデル201の終わりの出口ステートSDとを備える。これらの目的を以下に説明する。

【0095】ワードモデル(WORD)201の各ステート Sは、そのステートで終わる有効パスの累積距離を記憶 する累積距離記憶D[S]を有する。本実施形態におい て、ワードモデル201は、現フレームfkの現アクテ ィブリスト (ACTIVE LIST) 203を有する。ここで、 現アクティブリストは、現フレームfkの有効パスの終 わりにあるワードモデルのステートを降順に登録する。 したがって、現アクティブリスト203の各ステート は、そのステートで終わる各有効パスの累積距離を記憶 する。この例において、現フレームfkの現アクティブ リスト203は、ステートS7、S5、S4、S3、S2、 S1、S0を登録している。現アクティブリスト203に 掲載されたステートはアクティブステートとして示され る。本実施形態において、ワードモデル201は、関連 付けられた新アクティブリスト(NEW ACTIVE LIST)2 05も有する。この新アクティブリスト205は、ステ ップS47で行われる処理の間に完成し、次のフレーム f k+1のための有効パスの終わりにおけるワードモデル 201のステートを登録する。

【0096】現アクティブリスト203および新アクティブリスト205の重要性を図23を参照して説明する。図23は、p1~p7の7つの有効パスを示し、7つの有効パスは、入力されたワードとワードモデル201との間の現フレームfkまでの7つのマッチング候補を示す。図示されるとおり、7つの有効パスp1~p7はそれぞれ、ワードモデル201のステートS7、S5、S4、S3、S2、S1、S0で終わっている。現アクティブリスト203で降順に登録されているのは、これら有効パスの終わりのステートである。新アクティブリスト205に登録すべきステートを決定するため、すなわち、次の入力フレームfk+1に残るパスを決定するため、ある入力パラメータフレームから他のパラメータフレームへの移行が許可されている状態を考慮しなければ

ならない。

【0097】入力発声音に対する標準モデルの時間圧縮 の最大量は、入力発声音の隣接するフレーム間において スキップできるステートの最大数によって決定される。 本実施形態において、この最大数は2に設定される。す なわち、DPプロセスは、図19に示される状態遷移図 に従う。入力発声音に対する標準モデルの時間伸長の最 大量は、同じステートにマッチし得る連続した入力フレ ームの最大数によって決定される。本実施形態において は、続いて入力される2つの連続フレームが同じステー トにマッチし得る。これらの状態を監視するため、各ス テートSは、関連する自己反復カウンタ、すなわち、SE LFを有する。SELFは、対応する有効パスが入力フレーム fkから次のフレームfk+1が同じステートで終わる度に インクリメントされる。したがって、例えば、パスp5 は、図23に破線で示されるパス207の1つまたはす べてに沿って伝わる。図23に示される他のパスp1~ p4およびp6、p7も、同様の方法で伝わる。2つ以 上のパスが同じ点で合う場合、最小の累積距離を有する パスが維持され、他のパスは捨てられる。さらに、パス の累積距離が刈り込みしきい値より大きい場合、このパ スも捨てられる。このように、新しいパスが連続的に作 成され、一方、他のパスは捨てられる。刈り込みしきい 値の目的は、各入力パラメータフレームのために処理さ れる有効パスの数を制限し、それによって、アルゴリズ ムに必要な時間量およびメモリを制限することである。 【0098】図24は、図21のステップS47で行わ れる処理ステップを詳細に示す。まず、ステップS71 でポインタLAが初期化される。また、ワードモデル2 ○1の出口ステートに記憶される累積距離、すなわちD [SD]は、大きい値を示すHUGEに設定される。ポイン タLAは、新アクティブリスト205に登録された最後 のアクティブステートを示すのに用いられる。最初、新 アクティブリスト205にはアクティブステートがな く、従って、ポインタLAは、出口ステートSDを示す ように設定される。ステップS73でシステムは、現ア クティブリスト203にアクティブなステートがあるか どうかをチェックする。言い換えれば、現ワードにおけ る、現フレームfkで終わる有効パスがあるかどうかチ ェックする。本例では、現アクティブリスト203には 7つのアクティブステートがあり、システムは各アクテ ィブステートを順次処理する。カウント変数iが与えら れ、カウント変数iは、現アクティブリスト203にお けるアクティブステートすべてをカウントするために用 いられる。カウント変数iは、ステップS75で0に設 定され、現アクティブリスト203の全アクティブステ ートが処理されるまで、ステップS79でインクリメン トされる。システムは、ステップS81でカウント変数 iと現アクティブリスト203のアクティブステートの 数naとを比較することによって、すべてのアクティブ ステートが処理されたかどうかを判断する。

【0099】現アクティブリスト203のすべてのアクティブステートがいったん処理されると、ステップS77の処理の間に発生された新アクティブリスト205が、ステップS83にて、処理されるべき入力発声音の次のフレーム f k+1の現アクティブリスト203に置き換えられる。実際には、2つのアクティブリストを示すために用いられるポインタを交換することによってこの処理は行われる。古くなった現アクティブリストは、次の入力フレーム f k+1の処理中に新アクティブリストとして上書きされる。最後に、ステップS85において、アクティブステートになり、新アクティブリスト205に登録された、ポインタLAによって示される最終ステートが図21に示されるステップS57で用いるために格納される。

【0100】ステップS77で行われる処理の概略を、 アクティブステートS7、S5を例に揚げて説明する。図 23に示されるように、アクティブステートS7、S5は それぞれ、パスp1、p2の終わりである。図25は、 2つの有効パスp1、p2の一部分を示し、有効パスp 1、p2はそれぞれ、現フレームfkのアクティブステ ートS7、S5で終わる。図25の破線は、各2つのパス p1、p2が次のフレームfk+1に伝わり得る態様を示 す。破線213で示すように、パスp1は、フレームf k+1で他のワードに拡張することができる。したがっ て、(アクティブステートS7に記憶される)パスp1 の累積距離は、出口ステートSDに複写される。破線2 15、217、219で示すように、パスp1は、ステ ートS9、S8、S7のそれぞれにも伝わり得る。したが って、パスp1の累積距離がステートS9、S8、S7に 複写される。更に、ステートS9、S8、S7は、降順に 新アクティブリスト205に追加され(ただし、入力フ レームと比較されず、当該ワードを離れる全てのパスの 最短累積距離を記憶するためだけに用いられる出口ステ ートは追加されない)、最終アクティブポインタLA は、最後に追加されたステート(すなわち、ステートS 7)を示すように設定される。

【0101】図26aは、現アクティブリスト203の 第1のステートS7が処理された後の新アクティブリスト205を示す。図示されるように、ステートS9、S 8、S7はそれぞれ、新アクティブリスト205の最初の 3つの要素で、最終アクティブポインタLAは、ステートS7を示す。

【0102】図25をもう一度参照すると、破線22 1、223、225、227で示すように、パスp2 は、ステートS8、S7、S6、S5それぞれに伝わり得 る。しかしながら、2つのステートS8、S7は次のフレ ームfk+1のために記憶された累積距離をすでに有する ので、パスp2の累積距離を単に各ステートにコピーす るという処理だけではない。すなわち、これら2つのス テート S8、S7では、すでに記憶されている累積距離とパスp 2に関連する累積距離とを比較し、最小の累積距離がこれら2つのステートにコピーされることになる。言い換えれば、図23に示されるパスのステート S8、S7に記憶されるべき累積距離は、アクティブステート S5を処理した後に、min(D[S7], D[S5])によって求められる。一方アクティブステート S5に記憶された累積距離はステート S6に直接に複写される。ステート S6には、次のフレーム fk+1に対する累積距離が記憶されていないからである。2つのステート S6、S5は、新アクティブリスト 205に追加され、最終アクティブポインタLAは、ステート S5を示すように設定される。

【0103】図26bは、現アクティブリスト203の第2番目のアクティブステートS5が処理された後の新アクティブリスト205を示す。図示されるように、ステートS8、S7、S6、S5はそれぞれ、新アクティブリスト205の最初の5つの要素となり、最終アクティブポインタLAは、ステートS5を示す。現アクティブリスト203の他のアクティブステートも同様の方法で処理され、処理は図21で示されるステップS49に進み、ここでワードカウントがインクリメントされる。

は、ここでワートガリントがインクリスントされる。 【0104】最終アクティブポインタLAが設けられているので、システムは比較処理を必要とするステートおよび比較を必要としないステートを確認するために新アクティブリスト205を検査する必要が無くなる。即ち、ステートがアクティブポインタLAによって示されたステート番号と等しいかまたは上回る場合、比較処理が必要であることがわかる。また、ステート番号よりも下回る場合、累積距離がそのステートにコピーされればよい。

【0105】図24に示されるステップS77で行われ る処理を、図22に示されるワードモデル201の例を 用いて、図27aおよび図27bを参照して詳細に説明 する。ステップS77でi=0の場合に、処理をしなけ ればならない第1のアクティブステートSは、ステート S7である。したがって、図27aのステップS91 で、システムは、ステートS7で終わる有効パスの累積 距離が刈り込みしきい値Thを下回るかどうかをチェッ クする、すなわち、D[S7]はThと比較される。 D [S7] が刈り込みしきい値Thを上回る場合、このパ スは捨てられ、処理は、図24に示されるステップS7 9に移行する。 D[S7]が刈り込みしきい値Thを下 回る場合、処理は、ステップS92に進み、ここで現フ レーム fkのために処理されるアクティブステートの総 数を数えるために用いられる変数ACOUNTをインクリメン トする。ステップS93で、システムは、処理中である 現アクティブステートS7と処理中である現フレームfk との間の局部距離を計算し、この計算結果を累積距離D 「S7]に加算する。

【0106】本実施形態においては、以下のユークリッ

ドの距離公式を用い、現フレームfkと現アクティブステートSとの間の局部距離の値を得る。

[0107]

【数8】

$$d(s, f_k) = ||S - f_k||^2 \qquad \cdots (8)$$

【0108】累積距離D「S7]がステップS93で更 新された後、ステップS95でシステムは、現アクティ ブステートS7で終わる有効パスが次の入力フレームfk +1でワードから離れ得るかどうかをチェックする。上記 DPの制限によって、この処理では、処理される現アク ティブステートSの先の3つ目のステートがワードモデ ル201の最後のステートの先に進むかどうかを決定し て示す。本例では、現アクティブステートS7の先の3 つのステートが最後のステートS9を過ぎているので、 ステップS97に進み、ワードモデル201の終わりで ある出口ステートSDを示すようにポインタjが設定さ れる。ステップS101で、ポインタ」によって示され るステートが最終アクティブポインタLAによって示さ れるステートと比較される。この処理は(現時点で は)、処理されるべき現アクティブリスト203内の第 1番目のアクティブステートであるので、最終アクティ ブポインタLAは、出口ステート SDを示している(図 24に示されるステップS71を参照)。したがって、 処理はステップS103に進み、ここでポインタ」によ って示されたステート、すなわち、出口ステートSDに 記憶された累積距離が、処理される現アクティブステー トS7で終わる有効パスp1の累積距離と比較される。 【0109】図24のステップS71で、出口ステー ト、すなわち、D[SD]に記憶された累積距離は、大 きな値を示すHUGEに設定されている。したがって、累積 距離は、処理される現アクティブステートS7に記憶さ れている累積距離を上回る。結果的に、処理は、ステッ プS105に進み、ここでD[S7]がD[SD]にコピ ーされる。次に、ステップS107で、ポインタ j によ って示されるステート、すなわち、出口ステートSDに 対応する自己反復カウンタは〇に設定される。ステップ S109で、ポインタ j はデクリメントされ、ステート S9を示すようになり、処理はステップS101に戻

【 0 1 1 0 】次に、ポインタ」によって示されるステート (ステートS9) は、最終アクティブボインタLAによって示されるステート (ステートSD) の前なので、処理は図2 7 bに示されるステップS 1 1 1 に進む。ステップS 1 1 1 で、システムは、ポインタ」によって示されるステート、すなわち、ステートS9が処理される現アクティブステートS7と等しいかどうかをチェックする。ここでは、等しくないので、処理はステップS 1 1 3 に進み、ここでステートS9に記憶された累積距離が現アクティブステートS7に記憶された累積距離と等

しくされる。言い換えれば、パスp1の累積距離がステート S9に複写される。そして、ステップ S115で、ステート S9が、図22に示される新アクティブリスト205に追加される。ステップ S117で、ステート S9に対応する自己反復カウンタが0に再設定される。そして、続くステップ S119でポインタ j がデクリメントされ、ポインタ j はステート S8を示す。処理はステップ S111に戻り、ステート S8はステート S9と同様の方法で処理される。

【0111】ステートS8がステップS113、S11 5、S117で処理された後、jはステップS119で デクリメントされてステートS7を示すようになる。ス テートS7は処理される現アクティブステートでもあ る。したがって、このとき、処理はステップS111か らステップS121に進み、ここでステートS7に関連 する自己反復カウンタがチェックされる。すなわち、ス テートS7で終わる有効パスが、当該入力発声音の過去 の2つのフレームに渡ってそこで終わったかどうかをチ ェックする。ステートS7に対応する自己反復カウンタ の値が2つのフレームと等しい場合、ステートS7は新 アクティブリスト205には追加されず、処理はステッ プS123に進む。ステップS123では、最終アクテ ィブポインタLAが、現アクティブステートに1を加え られた値に設定され、ステートS8を示すようになる。 このルーチンによって、現アクティブステートに対応す る自己反復カウンタが2つのフレームと等しいかどうか 確認され、等しい場合には現アクティブステートで終わ る有効パスが、次のフレーム f k+1の同じステートに伝 わることを防ぐ。 図23に示されるパスの例において は、現フレームfkのステートS7で終わるパスp1はス テートS6から入るので、自己反復カウンタはOとなっ ている。結果的に、ステートS7は、ステップS125 で新アクティブリスト205に追加される。ステートS 7の自己反復カウンタは、ステップS127でインクリ メントされ、ステップS129で、最終アクティブポイ ンタLAが現アクティブステート、すなわち、ステート S7を示すように設定される。

【0112】ステップS129またはステップS123の後、処理はステップS131に進み、ここで現アクティブステートS7に記憶された累積距離は、現フレーム fkのために処理されたすべてのワードにおけるすべての有効パスの最短累積距離MINSCOREと比較される。ステートS7に記憶された累積距離がMINSCORE を下回る場合は、ステップS133でMINSCOREがステートS7に記憶された累積距離に置き換えられる。その後、処理は、図24に示されるステップS79に戻る。一方、MINSCOREに記憶された累積距離が現ステートS7に対応する累積距離を下回る場合、処理は、そのまま図24に示されるステップS79に戻る。ステップS79に戻ると、カウント変数iがインクリメントされ、現アクティブリスト

203の次のアクティブステート、すなわち、ステート S5が、ステップS77で処理されることになる。

【0113】アクティブステートS5は、上記アクティ ブステート S7と同様の方法で処理される。ステート S5 で終わる有効パスの累積距離が刈り込みしきい値Thを 下回る場合、ステップS93で、システムは、現アクテ ィブステートS5と処理される現フレームfkとの間の局 部距離を計算し、その計算結果を現アクティブステート S5に記憶された累積距離に加算する。ステップS95 で、システムは、現アクティブステートS5で終わるパ スp2が、上記DPの制限によって、次のフレームfk+ 1の他のワードに拡張できないと判断する。言い換えれ ば、ステートS5から3つ目のステートは、ステートSD と等しくないかまたはステートSDを越えないので、処 理はステップS99に進み、ここでポインタうが、ステ ートS5の3段階先のステート、すなわち、ステートS8 を示すように設定される。次に、ステップS101で、 ポインタ」によって示されるステートが、最終アクティ ブポインタLAによって示されるステートと比較され

【0114】この時点において、最終アクティブポインタLAはステートS7を示し、ポインタjはステートS8を示す。したがって、処理がステップS103に進み、ここで(アクティブステートS7の処理の結果として)ステートS8にすでに記憶されていた累積距離が、アクティブステートS5に記憶された累積距離と比較される。ステートS8に記憶された累積距離がステートS5に記憶された累積距離は、ステートS5に記憶された累積距離に置き換えられる。ステップS107で、ステートS8に関連する自己反復カウンタは0に再設定され、ポインタjは、ステップS109でデクリメントされ、ステートS7を示すようになる。そして、処理はステップS101に進み、ここで上記と同様の処理が行われる。

【 0 1 1 5 】この再帰処理ルーチンは、システムに認知 されたすべての標準ワードの全ての現アクティブステー トについて行われる。

【0116】現フレームfkについて上記方法で各ワードを処理した後、言語モデル21の各ノードが順次処理される。上記のとおり、言語モデル21は、許容されるワードのシーケンスを決定する。この情報は、ノードによって、特にノードの入力および出力に接続されるワードによって、決定される。図21のステップS51のノードの処理によって、有効パスは確実に許容されたワードシーケンスの中を伝わる。以下、ステップS51で行われる処理を、図28を参照して詳細に説明する。

【0117】まず、ノードを処理する前に、バックグラウンドのノイズを示すフレームと現フレーム fk(すなわち、d(noise, fk))との間の局部距離が、ステップS151で計算される。ステップS153で、ノードポ

インタvがスタートノードN0を示すように初期化され る。ステップS155で、ノードポインタャによって示 されるノードに記憶された累積距離、すなわち、D 「v]が、刈り込みしきい値Thと比較される。 D [v]が刈り込みしきい値Thを下回る場合、処理はス テップS157に進み、ここでd(noise, fk)が、処理 される現ノードマに記憶された累積距離に加算される。 ステップS159で、システムは、D[v]と最小値記 憶MINSCOREに記憶された値を比較する。 D「v〕がMIN SCOREに記憶された値を下回る場合、ステップS161 でD[v]をMINSCOREにコピーする。カウント値ACOUNT (現フレームのために処理されたアクティブステートお よびノードの数を示す) はステップS163でインクリ メントされ、処理はステップS165に進む。一方、ス テップS155において、D[v]が刈り込みしきい値 Thを上回る場合は、ステップS167でD[v]は大 きな値を示すHUGEに設定され、処理はステップS165 に進む。

【0118】ステップS165、S168で行われる処理について、図29に示されるノードNを例にして説明する。図示のノードNには、3つのワード「get」、「save」、「load」がその入力に接続され、2つのワード「an」、「the」がその出力に接続されている。このようなノードの生成は、図17bに示される手順を用いては実現できないが、ダイナミックプログラミングプロセスがより複雑な言語モデルのために動作することを示すために本例が選択されている。特に、定型文法では、ノードが図29に示されるようなものが一般的である。

【0119】ステップS165で、システムは、ノード Nの入力に接続されたワードの出口ステート、すなわ ち、ワード「get」、「save」、「load」の出口ステー トに記憶されたすべての累積距離の最小値を決定する。 一般的な場合、この計算は以下の式によって、示され る。

[0120]

【数9】

$$\underset{\{I_w[V]\}}{MIN}(D[S_D]) \qquad \cdots (9)$$

【0121】ここで、Iw[v]は、ノードvの入力に接続されたすべてのワードを示す。システムがノードNについてこの最小累積距離を決定した後、その最小累積距離がすでに記憶されている累積距離を下回る場合には、当該最小累積距離がノードNに記憶された累積距離D[N]に複写される。事実上、これは、当該ノードの入力に接続されたワードの一つであって、現在そのノードにおいて成長しているパスの累積距離よりも小さい累積距離を有する有効パスが存在するかどうかの判断である。

【0122】バックグラウンドのノイズフレームにマッチするギャップが、フレーズ内の各ワードの手前、間及

び終わりに存在し得るので、有効パスはそのノード内を 伝わることができる。 図29の矢印231が示すよう に、有効パスが、入力されたフレームから次の入力フレ ームまでの間1つのノードに残ることもできる。この場 合、有効パスはノードNを出発してノードNに戻る。ワ ードモデルのステートと異なり、パスは、連続して入力 されたフレームのいくつ分でも、ノード内に残ることが 可能である。システムがステップS165の処理を行っ た後、ノードNに記憶された累積距離がすでに記憶され ている値より小さい場合、ノードNに記憶された累積距 離は、ステップS168で、一時的記憶INSCOREに複写 される。この一時的記憶INSCOREは、ワード「an」、「t he」のためのボックス233、235で示される。2つ 以上のワードがノードの出力に接続されるので、比較処 理が行われなければならない。接続ワードに伝わるのは 最小累積距離を有するパスだけだからである。図21に 示されるステップS57の処理において、ワードの一時 的記憶INSCOREに記憶された累積距離を用いて当該ワー ドのエントリステートが更新される。

【0123】ステップS169で、システムは、D [v]がHUGEに等しいかどうかをチェックする。等しい 場合、終了する有効パスが無いかまたは、ノードvを通 過して次のフレーム f k+1に接続されたワードに入って いる有効パスが無いことを示す。D[v]が値HUGEを下 回る場合、有効パスが、ノードマで終わっているかまた は、ノード v を通過して、次のフレーム f k+1でノード vに接続されているワードに入っていることを示す。し たがって、次のフレーム f k+1における潜在的にアクテ ィブなステート(およびノード)の数を表すカウンタPA COUNTは、そのノードに関連する沈黙ステートが次のフ レーム f k+1でアクティブステートとなり得るので、ス テップS171でインクリメントされる。ノードポイン タvは、ステップS173でインクリメントされ、言語 モデル21の次のノードを示すようになる。システム は、ステップS175で、ノードポインタャが言語モデ ル21のエンドノード Nnを越えるノードを示すかどう かをチェックすることによって、言語モデル21のすべ てのノードが処理されているかどうかをチェックする。 システムがすべてのノード処理を完了していない場合、 処理はステップS155に戻る。一方、処理を完了して いる場合、処理は図21に示されるステップS53に戻

【0124】次に、図21に示されるステップS57で行われる処理を、図22に示されるワードモデル201、図30および図31を参照して、詳細に説明する。図30において、ステップS181でシステムは、INSCOREに記憶された累積距離がHUGEと等しいかどうかをチェックする。等しい場合、次の時点でこのワードに入る有効パスがないことを示す。したがって、このワードを再処理する必要がないので、処理はステップS207に

進み、ここで次の入力フレーム f k+1のアクティブステートの数(図24のステップS83の処理によって現アクティブリスト203に現在記憶されているステートの数となる)が、カウントPACOUNTに加算される。その後、処理は、図21に示されるステップS59に戻り、ここでワードカウントがインクリメントされ、次のワードモデルが処理される。

【O125】他方、INSCOREがHUGEと等しくない場合 は、有効パスが先のワードを出て、処理すべき現ワード に入っていることを示す。したがって、別のワードモデ ル (エントリステート) から延びてきたパスによって到 達され得る現ワードモデルのステートは、INSCOREに記 憶された累積距離を用いて更新されなければならない。 上記DP制限を用いる本実施形態において、エントリス テートは、ステートSO、S1、S2である。この更新手 順は、以下の方法で行われる。まず、ステップS183 で、システムは、処理される現ワードを示すワードモデ ルが(出口ステートは含まない)3つより多いステート を含むことをチェックする。3つより多いステートがあ る場合、ステップS185でステートS2を示すように ステータスポインタ」が設定される。他方、現ワードの ステートが3つより少ない場合、ステップS187でス テータスポインタうが、当該処理ワードの終わりの出口 ステートSDを示すべく設定される。このように、ステ ップS187またはS185でステートSD、S2のいず れかに向かうようにステータスポインタ」が設定される と、処理はステップS189に進み、ポインタ」によっ て示されたステートと最終アクティブポインタLAによ って示されるステートとが比較される。

【0126】図27aおよび27bにおいてステップのシーケンスで行われた処理のように、ポインタjによって示されるステートが、アクティブポインタLAによって示されるステートを越える場合、そのステートに既に記憶された累積距離とINSCOREに記憶された累積距離が比較される。

【0127】図23に示されるDPパスの例として、パスp7は、次のフレーム f k+1でステートS1、S2、S3 に伝わり得るが、ステートS0には伝わらない。パスp7が先の2つのフレームにおいてステートS0で終わっているからである。したがって、最終アクティブポインタLAは、ステートS1を示すようになる(ステップS121、123)。

【0128】図31は、図22に示されるワードモデル201のエントリステート(すなわち、最初の3つのステート)を示す。図示されるように、アクティブポインタLAは、ステートS1に向かう。ワードモデル201に3つよりも多くのステートがあるので、ステータスポインタ」は、ステートS2を示す。ステップS189で、システムは、ポインタ」によって示されたステートが、最終アクティブポインタLAによって示されたステ

ート、すなわちステートS1を過ぎているかどうかを判。 断する。したがって、ここでは、処理はステップS19 1に進む。ステップS191で、システムは、ステート S2に記憶された累積距離と、ワードモデル201に関 連する一時的記憶INSCOREに記憶された累積距離とを比 較する。ワードモデル201の一時的記憶INSCOREは、 図31に示される矩形のボックス241で示される。IN SCOREに記憶された累積距離がステート S2に記憶された 累積距離より小さい場合、ステップS193でINSCORE に記憶された累積距離がステートS2に複写される。そ して、ステップS195で、ステートS2の自己反復力 ウンタがOに再設定され、処理はステップS197に進 む。一方、INSCOREに記憶された累積距離がステートS2 に記憶された累積距離より大きい場合、ステートS2に 記憶された累積距離は変化せず、処理はステップS19 7に進む。ステップS197において、ポインタ」はデ クリメントされ、ステートS1を示すようになる。処理 はステップS189に戻り、同様の処理が、ステートS 1について行われる。

【0129】ステートS1について処理した後、ポイン タjは、ステップS197で再びデクリメントされ、ス テートSOを示すようになる。したがって、処理はステ ップS189からステップS198に進み、ここでシス テムは、処理すべきステートがあるかどうかをチェック する。本例の場合、ステートSOがまだ処理されるべき であるので、処理はステップS199に進む。ステップ S199において、INSCOREに記憶された累積距離が、 ステートS0に複写される。このステートは、最終アク ティブポインタLAによって示される最後のアクティブ ステートの手前なので、ステートS0について累積距離 の比較は行われない。ステップS201で、システム は、ステートS0を現アクティブリスト(このリスト は、図24のステップS83の処理の前では新アクティ ブリスト205だったものである)に追加する。そし て、ステップS203で、ポインタ j はデクリメントさ れ、ステートS 1を示すようになる。その後、処理はス テップS198に戻り、ここでシステムは、処理される べき現ワードにエントリステートがこれ以上ないと判断 する。従って処理はステップS205に進み、ここで対 応する一時的記憶INSCOREに記憶された累積距離が、HUG Eに再設定される。そして、ステップS207で、現ア クティブリストのステートの数が、カウントPACOUNTに 追加され、処理は、図21に示されるステップS59に 戻る。

【0130】<刈り込み(Pruning)>図21によれば、ステップS63で、処理されるべき入力フレームが更に存在するとシステムが判断した場合、処理はステップS65に進み、ここで刈り込みしきい値Thが調整される。刈り込みを用いる目的は、ある時点からつぎの時点まで伝わるDPパスの数を制限することである。特

に、本実施形態では、刈り込みしきい値を調整し、実際に処理されるアクティブステートの数を前もって決められた範囲に制限できるようにすることを狙う。なお、この限られた範囲は、利用できる動作メモリの量および処理時間によって左右される。さらに、本実施形態の目的は、高価なコンピュータ処理のオーバーヘッドを必要とせずに、以上の目的を達成させることである。本実施形態において、刈り込みしきい値は、可変差分値(PRUNING)を処理された入力フレームのために決定されたすべての最小累積スコアMINSCOREに追加することによって、決定される。すなわち、刈り込みしきい値は、等式(10)によって、求められる。

[0131]

【数10】

 $Th = MINSCORE + PRUNING \cdots (10)$

【0132】アクティブステートの設定数のみが各入力 フレームのために処理されることを確実にする方法の1 つは、そこに記憶された累積距離を増加させるために、 処理されつつある入力フレームに対するすべてのアクテ ィブリストにあるアクティブステートをソートし、最小 累積距離を有する入力フレームで始まる所望の数を処理 する。しかしながら、この技術は、アクティブステート をソートするために長時間のコンピュータ処理時間を要 する。コストのかかるコンピュータ処理によるソートを 行うのではなく、本実施形態で用いられる技術は、最後 の入力フレームを処理した後に利用できる情報を用い る。特に、本実施形態において、差分値(PRUNING) は、処理されるべき次の入力フレームの潜在的なアクテ ィブステートの数(PACOUNTに格納されている)に依存 して変化し、実際に処理されるステートの数を2つのし きい値の間にあるように維持する。 刈り込みしきい値T hが調整される方法を、図32を参照して詳細に説明す る。

【0133】ステップS211において、システムは、処理される次のフレームの潜在的アクティブステートの数(PACOUNTに記憶される)とステートしきい値(STATE TH)を比較する。ここで、ステートしきい値(STATET H)は、利用できる動作メモリの量によって決定される絶対的最大ステートしきい値を下回るが、その値の付近に設定される。PACOUNTに記憶された値がSTATETHを下回る場合、すべての潜在的なアクティブステートが処理され得ることを意味するので、直前の時点で用いられた差分値PRUNINGは増加される。したがって、ステップS213で、調整定数dp1が既存の差分値PRUNINGに追加される。dp1の値は、妥当な局部距離を上回るように設定されるので、すべてではないがほとんどの潜在的アクティブステートが処理される。

【0134】PRUNINGに記憶された値は、ステップS2 15で、高い刈り込みしきい値HIGHPRTHと比較される。 上限が差分値PRUNINGに設定されているので、これ以上 進む必要のない最大差分値が存在する。 PRUNINGに記憶された値がHIGHPRTHを下回る場合、処理はステップS 2 19に進む。 一方、PRUNINGに記憶された値がHIGHPRTHを上回る場合、PRUNINGは、ステップS 2 17で、HIGHPRTHに設定される。ステップS 2 15またはS 2 17の処理の後、システムは、差分値PRUNINGを追加された他の有効パスの最小累積距離MINSCOREとPRUNINGとの和に等しくなるように刈り込みしきい値Thが設定される。そして、処理は、図21に示されるステップS 43に戻る。

【0135】ステップS211で、次のフレームの潜在 的アクティブステートの数(PACOUNT)がSTATETHを上回 るとシステムが判断した場合、ステップS221で、シ ステムは、直前の入力フレームの処理においてアクティ ブステートとして処理されたステートの数(ACOUNTに記 憶されている)と、低ステートしきい値LOWSTTHとを比 較する。このLOWSTTHの値は、ACOUNTがLOWSTTHを下回っ た場合には、多くの時間またはメモリ量を費やさずに次 の入力フレームのすべての潜在的なアクティブステート を処理できることを保証できるような値に設定される。 したがって、ACOUNTがLOWSTTHを下回る場合、処理はス テップS221からステップS213に進み、上述した ような処理によって差分値PRUNINGが調整される。他 方、ACOUNTがLOWSTTHを上回る場合、すべての潜在的ア クティブステートが処理された場合に、それほどの処理 時間またはメモリ量を費やさずに済むという保証は無 い。したがって、差分値PRUNINGを低減する必要がある かもしれない。

【O136】差分値PRUNINGを低減させる必要があるか どうかを判断するため、システムは、ステップS223 で、ACOUNTとSTATETHを比較する。ACOUNTがSTATETHを下 回る場合、システムは、差分値PRUNINGがHIGHPRTHと等 しいかどうかをチェックする。差分値PRUNINGがHIGHPRT Hと等しい場合、システムはすべてのアクティブステー トを処理するように試みてきたことを示す。したがっ て、次の入力フレームのために処理されるアクティブス テートの数によって、長時間の処理時間または大容量メ モリを要する処理になってしまうようなことはまず起こ らないとみてよい。したがって、差分値PRUNINGを変化 させずにステップS219に処理を進め、ここで刈り込 みしきい値は、MINSCOREに差分値PRUNINGを加算したも のと等しくなるように設定される。他方、差分値PRUNIN GがHIGHPRTHと等しくない場合(この場合、差分値PRUNI NGがHIGHPRTH を下回ることになる)、次の入力フレー ムのために処理されるアクティブステートの数は、長時 間の処理時間または大容量のメモリを費やす可能性があ る。したがって、処理されるアクティブステートの実際 の数が計算されなければならない。この計算は、変更さ せていない差分値PRUNINGを用いてステップS231で 設定された刈り込みしきい値を用いてステップS233

で行われる。

【0137】ステップS223に戻って、ACOUNTがSTAT ETHを上回るとシステムが判断した場合、ステップS2 25で、差分値PRUNINGは、調整定数dp1によって低 減される。ステップS225で差分値PRUNINGが減らさ れた後、システムはステップS227において、差分値 PRUNINGが低刈り込みしきい値LOWPRTHを下回るかどうか を判断する。低刈り込みしきい値は、次の入力フレーム について処理されるアクティブステートの数が設定され た非常しきい値EMGSTTHを上回ることを保証するのに用 いる。この処理を行う理由は、大量に刈り込まれた場 合、ダイナミックプログラミングプロセスが行えないか らである。差分値PRUNINGが低刈り込みしきい値LOWPRTH を下回る場合、ステップS229で差分値PRUNINGをLOW PRTHに等しくする。ステップS231では、調整された 差分値PRUNINGをMINSCOREに加算したもの等しくなるよ うに刈り込みしきい値Thが設定される。次にステップ S233で、システムは、次の入力フレームのために処 理されるアクティブステートの数をカウントする。この 処理は、すべてのアクティブステートに記憶された累積 距離と、新たに決定された刈り込みしきい値Thを有す るすべてのノードに記憶された累積距離とを比較するこ とによって行われる。

【0138】総数 (nsa) は、次の入力フレームに関し て処理されるアクティブステートとノードの総数を示 す。総数nsaが非常しきい値EMGSTTHを下回る場合、刈 り込みしきい値の設定が低すぎることを意味する。従っ て、処理はステップS213に進み、ここで差分値PRUN INGが増加され、刈り込みしきい値Thが再設定され る。一方、nsaが非常しきい値EMGSTTHを下回らない場 合、ステップS237で、nsaはLOWSTTHと比較され る。 nsaがLOWSTTHを上回る場合、ステップS231で 設定された刈り込みしきい値Thは受け入れ可能であ り、処理は、図21に示されるステップS43に戻る。 他方、nsaがLOWSTTHを下回る場合、刈り込みしきい値 は増加させることができる。よって、ステップS219 で刈り込みしきい値Thが再設定される前に、ステップ S239で、第2の調整定数dp2を差分値PRUNINGに 加算する。本実施形態において、この第2の調整定数d p2は、調整定数dp1の半分に設定される。

【0139】当業者には明らかなように、刈り込みしきい値を変化させる方法はコンピュータ処理に高価なコストを費やさせない。さらに、各時点で処理されるアクティブステートの数を制限するという方法を用いて刈り込みしきい値が調整される。このため、割り当てられる処理時間およびメモリが限界を越えないように調整することができる。

【0140】図21に示される処理ステップのシーケンスを用いて入力シーケンスのすべてのフレームが処理された後、ダイナミックプログラミングプロセスによって

決定された最適パスにより正しいパスを決定するために バックトラッキングルーチンが要求される。本実施形態 において、バックトラッキングルーチンは、各パスが伝 わるワードのシーケンスを示すバックポインタを追跡す る。このようなバックトラッキングルーチン(再帰ルー チン)が行われる方法、およびポインタを発生させる方 法の詳細については、音声処理の当業者によく知られて いるので、これ以上説明はしない。

【0141】<初期化>システムに入力発声音を認識さ せる前に、認識処理中に用いられるシステムのしきい値 および変数を初期化しなければならない。この処理は、 以下の方法で行われる。まず、スタートノードN0に記 憶される累積距離は0に設定され、他のノードに記憶さ れる累積距離は、大きな値を示すHUGEに等しくなるよう に設定される。各ワードモデルに関連付けられ、潜在的 なアクティブステートの数をカウントするカウンタPACO UNTはOに設定される。各ワードモデルに関連付けられ た最終アクティブポインタLAは、それぞれのモデルの エンドステートSDを示すように設定される。各ワード モデルに関連付けられた一時的記憶INSCOREは、大きい 値を示すHUGEに設定される。その後、すべてのノードが 処理され、各ワードの入力に接続されるすべてのノード の累積距離の最小値は、各ワードに関連付けられた一時 的記憶INSCOREに複写される。これは、スタートノード NOに接続された各ワードの一時的記憶INSCOREが O に設 定されることを保証する。最後に、各ワードのINSCORE に記憶された値を用いて、各ワードモデルのエントリス テートを作動させ、初期化する。各ワードモデルのエン トリステートを初期化する処理ステップは、図30を参 照して上述したエントリステートを更新するために用い られる処理ステップと同一である。刈り込みしきい値お よび差分値PRUNINGもまた、第1の入力フレームを処理 する前に、初期化される。特に、刈り込みしきい値Th は大きい値を示すHUGEに設定され、差分値PRUNINGは、 高刈り込みしきい値HIGHPRTHと等しくなるように設定さ れる。

【0142】<フレキシブルダイナミックプログラミングアラインメント>上記において、本実施形態におけるワードモデルの生成方法について、図13から図16を参照して詳細に説明を行った。特に、先ずはじめに、フレーズに含まれるワードについて分離ワードモデルが、フレキシブルダイナミックプログラミングアラインメントを用いて生成される。すなわち、フレキシブルダイナミックプログラミングアラインメントを用いて、そのフレーズに対応するパラメータフレームのシーケンスを、分離して発声された当該フレーズに含まれるワードに対応するパラメータフレームに関連付けることで分離ワードモデルが生成される。以下、このフレキシブルアラインメントプロセスについて詳細に説明する。なお、ここでは、学習フレーズ「get an image」が与えられ、か

つ、そのフレーズに存在するワードに対するワードモデ ルが無い場合を例に揚げて説明する。

【0143】図33は、「get an image」というフレー ズの発声音声に対応するパラメータフレームシーケンス 152と、「get」、「an」及び「image」の各分離ワー ドの発声音声に対応するパラメータフレームシーケンス 158、160及び162を示す。 パラメータフレーム シーケンス152におけるパラメータフレームの幾つか はバックグラウンドノイズもしくは沈黙に対応するの で、フレーズに含まれる各分離ワードの間、先頭の分離 ワードの開始部分、最終の分離ワードの後部分にノード 251、253、255、257が提供される。これら のノードは図17aで示された言語モデル中のノードに 類似の態様で動作し、処理中であるパラメータフレーム 152の現パラメータフレームが沈黙もしくはバックグ ラウンドノイズに対応したものであるという状況に対応 可能である。この可能性は、図33において、ノード2 51,253、255及び257における沈黙フレーム f si1 (これは図10において示されたノイズモデル2) 3である)によって示されている。

【0144】パラメータフレームシーケンス158、160、162のそれぞれの開始部分もしくは終了部分におけるフレームのいくつかは沈黙或いはバックグラウンドノイズに対応するものであるかもしれないが、パラメータフレームシーケンス152内の沈黙成いはバックグラウンドノイズに対応するパラメータフレームは、シーケンス158、160及び162内の沈黙に対応するフレームよりも、ノード251、252、255及び257に格納された沈黙フレームfsilによりよくマッチする。これは、沈黙フレームfsilが全沈黙フレームの平均を示すものであり、シーケンス152内の沈黙に対応するフレームと沈黙フレームfsilとの間の変動量が、シーケンス152内の沈黙に対応するフレームと各シーケンス158、160及び162内の沈黙に対応するフレームとの間の変動量よりも小さいからである。

【0145】フレキシブルアラインメントプロセスが実行される方法は、図18~32を参照して説明したような、入力音声が、格納されている標準モデルに関連付けられる方法に類似している。特に、パラメータフレーム158、160及び162を標準モデルとして、ノード251、253、255、257、そしてシーケンスフレーム152を入力されたフレームとして用いる場理スフレキシブルアラインメントプロセスの全体的な処理ステップは図21に示されたフローチャートに従う。混乱を避けるために、分離的に発声されたワードを表すパラメータフレームシーケンス158、160、162は、ステートと称する。未知の入力音声を認識するために用いられた標準モデルのステートと同様に、これらのステートも関連する累積距離格納部を有する。この累積距離格納部は、処理中のシーケンス152の現フレームに関

して、当該ステートまでのダイナミックプログラミングパスの累積距離を格納する。

【0146】フレキシブルアラインメントプロセスと未知の入力発声音声を認識するために用いられたアラインメントプロセスとの主要な相違は次の通りである。すなわち、フレキシブルアラインメントにおいては、(i)各ダイナミックプログラミングパスがあらゆる位置で(エントリステートの一つに限らず)ワードに入ることができる、(ii)各ダイナミックプログラミングパスはそこに存在するあらゆるステートから出ることができる。

【0147】フレキシブルアラインメントプロセスの動作を上記例を用いて以下に説明する。なお、以下の説明は、シーケンスパラメータフレーム152のはじめの少しのパラメータフレームについて行う。

【0148】まず、第1のフレームを処理する前に、ノード及びワードモデル内のステートの累積距離スコアを初期化する。この初期化処理手順は、上述の、未知入力音声を認識するのに先立って実行される初期化処理に類似している。特に、スタートノード、すなわちノード251に格納される累積距離はゼロに設定され、他の全てのノードに格納される累積距離は大きな値を示すHUGEに設定される。その後、ワードW1、W2及びW3におけるステートの累積距離スコアは、それらのワードの入力に接続されたノードに格納された累積距離スコアを用いて更新される。これは、フレームf0P1が処理されているときに、ダイナミックプログラミングパスが第1のワードW1及び第1のノード251の各ステートからスタートできることを保証する。

【0149】初期化の後、第1フレームfOP1が、ワー ドW1、W2及びW3に関して順次処理される。しかし ながら、ワードW2及びW3内のステートに関連した累 積距離は値HUGEを有するので、第1ワードW1内のステ ートに関してのみ、第1フレームが処理されることにな る。ワードW1に関して第1フレームを処理する際、フ レームfOP1とワードW1内の各ステートとの間の距離 は各ステートに対応付けられた累積距離格納部に格納さ れる。フレキシブルアラインメントプロセスは図28に 示された処理ステップを用いて、ノード251,25 3、255及び257を順次処理する。最後に、ノード 処理の結果を用いてワードW1、W2及びW3内のステ ートの累積距離スコアを更新することにより、第1フレ ームfOP1の処理が完了する。この更新処理は、エント リステート(すなわち、最初の3つのステート)だけで なくワード内の全てのステートが更新されるということ を除けば、図30に示される処理と同様である。

【0150】シーケンス152の第1のパラメータフレームが処理されると、第1のパラメータフレームf0P1の処理によってスタートされたダイナミックプログラミングパスを成長させるために第2のパラメータフレーム

f 1P1が処理される。入力された発声音声の認識に用い られたダイナミックプログラミング手法で行ったよう に、各ワードW1、W2及びW3のステートは逆方向の 順序で処理される。ここで、本実施形態において、図1 9及び図20を参照して記述された伝搬の制限に類似し た制限が用いられる。相違点は、未知の入力音声を認識 する場合では最後の3つのステートからのみ現ワードを 抜けることが許されたが、あらゆるステートから現ワー ドを抜けることができるという点のみである。ワードW 1、W2及びW3が第2のパラメータフレームf1P1を 用いて処理されると、各ノード内で現在伝わっているダ イナミックプログラミングパスを更新するために、ノー ド251,253、255及び257が処理される。こ の処理がなされると、ノード処理の結果を考慮するた め、ダイナミックプログラミングパスを更新するため に、ワードW1、W2及びW3が再び処理される。

【0151】パラメータフレームシーケンス152の残りのパラメータフレームも、同様の方法で順次処理される。シーケンス152内の全てのパラメータフレームが処理されると、最も低い累積スコアを有するダイナミックプログラミングパスが決定される。パラメータフレームシーケンス158、160及び162内の開始及び終了フレームを特定するために、フレキシブルアラインメントプロセスの間の各ダイナミックプログラミングパスの成長が記録される。ここで、これら開始及び終了フレームは、対応するワードを表す(沈黙は表さない)それらパラメータフレームの境界を示す。

【0152】特に、ダイナミックプログラミングパスが手前のワードから、あるいはワードの手前からワードへ入ったときはいつも、そのダイナミックプログラミングパスが入ったステートが記録され、そのパスに関連付けられる。同様に、ダイナミックプログラミングパスがワードから出て、それが出たステートが記録されたとき、そのパスに関連するスコアはそのワードから出た全ての前のダイナミックプログラミングパスに関連するスコアよりも低い。従って、パラメータフレームシーケンス152内の最後のパラメータフレームが処理され、最良のスコアを有するダイナミックプログラミングパスに関連する記録をされると、パラメータフレームシーケンス158、160、162内のワードのおおよその開始及び終了位置が、ダイナミックプログラミングパスに関連する記録を参照することにより、特定される。

【0153】当業者には明らかなように、フレキシブルアラインメントプロセスに関する上記記載は、入力フレーズ中に含まれる各ワードについてワードモデルが存在しないという状況に特化されたものである。しかしながら、標準モデルの学習は自然に増加するように、すなわちユーザが適宜システムに学習させることができるように設計されているので、入力フレーズ中のワードに対するワードモデルが既に存在するという状況が発生し得

る。この場合、フレーズとこのワードとの間のアラインメントの最中において、既にワードモデルを有するワードに対しては通常のダイナミックプログラミングプロセスを適用し、まだワードモデルの存在しない他のワードに対してはフレキシブルダイナミックプログラミングアラインメントを適用するという、混合型のダイナミックプログラミングアラインメントプロセスが採用される。 【0154】図14のステップS25 S26を参照

【0154】図14のステップS25、S26を参照して説明したように、フレーズ内の未知のワードに対して分離ワードモデルが決定されると、それらはワードを含む入力フレーズのパラメータフレームシーケンスに関連付けられ、ワードモデルがその結果から生成される。

【0155】<ワードモデルの適用>本実施形態による音声認識システムの他の特徴は、図10のワードモデル19、ノイズモデル23および言語モデル21が構築/更新モジュール91によって更新され、修正されることである。したがって、記憶されたワードモデル19は、別のユーザの入力音声によって、修正されたり適応させられたりする。

【0156】図34は、ワードモデル19が別のユーザ に適用される方法を示すフローチャートである。ステッ プS251で、新しいユーザは、既知のワードまたはフ レーズをマイクロフォン7またはキーボード3を介して システムに入力する。したがって、構築/更新モジュー ル91は、新しいユーザから入力された発声音に対応す るパラメータフレームのシーケンスと、キーボード3を 介して入力された対応するテキストとを有することにな る。ステップS253で、システムは、入力発声音と、 当該発声音に存在することが認知されているワードの既 存のワードモデルとを、ダイナミックプログラミングル ーチンを用いて関連付ける。すなわち、ダイナミックプ ログラミングルーチンは入力発声音のパラメータフレー ムと適切なワードモデルとを関連付ける。ステップS2 55で、システムは、ワードモデルのステートをそのワ ードモデルに関連付けられたパラメータフレームのシー ケンスで直接に置き換える。ステップS257で、新し いユーザが他のフレーズを入力することを決定した場 合、処理はステップS251に戻り、同様のルーチンが 次の入力発声音のために再度行われる。ステップS25 7で、新しいユーザがこれ以上フレーズを用いないと決 定した場合、当該処理は完了する。

【0157】図35は、ワードモデル19が別のユーザのために用いられる第2の方法を示すフローチャートである。ステップS261で、新しいユーザは、マイクロフォンを介して複数回およびキーボードを介して1回、既知のワードまたはフレーズをシステムに入力する。したがって、構築/更新モジュール91は、パラメータフレームの複数のシーケンスおよびキーボード3を介して入力された対応テキストを有するようになる。ここで、これら複数のシーケンスは、新しいユーザによって発声

された既知のワードまたはフレーズに対応する。ステップS263で、システムは、各入力発声音と、当該発声音に含まれることが既知であるワードに対応する既存のワードモデルとを、ダイナミックプログラミングルーチンを用いて関連付ける。

【0158】ダイナミックプログラミングルーチンは、 各入力発声音のパラメータフレームと、適正なワードモ デルのステートとを関連付ける。ステップS265で、 システムは、ワードモデルのステートをワードモデルに 関連付けられたパラメータフレームの平均で置き換え る。本実施形態において、ワードモデルのステートが発 声音のパラメータフレームのいずれにも関連付けられな かった場合、システムは、置き換えられた隣接ステート を用いて捕間または外挿する。ステップS267で、新 しいユーザが他のフレーズを用いることを決定する場 合、処理はステップS261に戻り、同様のルーチンが 次のフレーズに対して再度行われる。ステップS267 で、新しいユーザがこれ以上フレーズを入力しないこと を決定すると、処理は完了する。したがって、当業者に 明らかなように、新しいユーザは、ユーザの便宜上、既 存のワードモデルを増加させながら用いることができ る。さらに、新しいユーザは、新しいワードまたはフレ ーズを上述した方法でシステムに追加することもでき

【0159】<他の実施形態>多数の変形が、本発明の 進歩性の概念から逸脱することなく、上記音声認識シス テムになされ得る。これら種々の変形例のいくつかを以 下に説明する。

【0160】上記実施形態においては、すべての発声音 が処理される前に受信されるが、本システムは、音声を 受信しながら処理するというように、ワードモデルを漸 進的に動作させることができる。このような実施形態に おいて、入力バッファが必要であるが、1つのフレーム に相当する入力音声、すなわち、20msecの音声を 記憶しさえすればよい。当業者には明らかなように、本 システムを動作させるため、入力された音声の1つのフ レームに対する処理のすべて(プリプロセッサおよび認 識ブロックで行なわれる)は、入力音声のその次のフレ ームについて、処理のための準備が整う前に完了してい なければならない。上記フレーム速度およびフレーム継 続時間を用いれば、入力音声のフレームを処理するため に費やされる時間は10msecを下回るにちがいな い。これは現在のプロセッサで達成し得るものである。 さらに、入力発声音の各フレームのパワーパラメータ は、異なる方法で正規化されなければならない。このよ うな実施形態におけるパワーの正規化の方法の1つとし ては、例えば過去の20個にわたる入力音声のパワーに 基づいて適応される適応正規化係数を用いることが揚げ られる。

【0161】また、第1の実施形態において、ダイナミ

ックプログラミングパスの終わりにあったワードモデル のステートは、そのワードモデルに対応するアクティブ リストに登録されていた。他の実施形態においては、総 括アクティブリストを1つ備え、そこに、すべてのワー ドモデルのすべてのアクティブステートを登録する。こ のような他の実施形態においては、総括アクティブリス トに関連して、特定のアクティブステートがどのワード モデルに属するかの情報が記憶されなければならない。 【0162】第1の実施形態において、ワードモデルの ステートは、持続時間において、認識されるべき入力音 声のフレームと対応する。他の実施形態において、ワー ドモデルの各ステートは、持続時間に関して、例えば入 力音声の3つの連続フレームと等しい。このような他の 実施形態において、入力フレームは、3つのフレームグ ループによって平均化され、ワードモデルのステートに 関連付けられる。

【0163】さらに、他の実施形態は、ワードモデルに 統計モデル、例えば隠れマルコフモデルを採用するもの であり、これは音声認識の当業者に知られている。この ような実施形態においては、入力発声音とワードモデル のシーケンスとの間の最小累積距離を決定するのではな く、隠れマルコフモデルの特定のシーケンスによって入 力シーケンスが生成された最大の可能性が決定される。 このような実施形態において、隠れマルコフモデルは、 第1の実施形態で発生された連続標準モデルと同様の方 法で発生される。特に、ワードの分離標準モデルは、ワ ードの発声音とそのワードを含むフレーズの1つ以上の 発声音とを比較することによって、生成される。平均パ ラメータフレームおよび隠れマルコフモデルのステート の共分散マトリクスを生成し、ステートの遷移確率を生 成するために、分離標準モデルはワードを含む複数のフ レーズ例とともに用いられる。この処理が行われる方法 は、音声認識の当業者には明らかである。

【0164】第1の実施形態において用いられる標準モ デルは、すべてのワードに対応する。当業者に明らかな ように、このことは本質的なことではない。標準モデル は、ワードの部分、例えば、音節、複数のワード、個々 の音素にさえ相当する。しかしながら、音素に相当する 標準モデルを用いると、システムが言語に依存するよう になり、不利である。すべてのワードに対応する標準モ デルは、すべてのフレーズに対応する標準モデルより好 ましい。なぜなら、時間およびコンピュータ処理の手間 を節約することができるからである。特に、フレーズ内 のワードをモデルにし、言語モデルを用いることによっ て、システムに少量のワードしか用いない多くの異なる フレーズを教えられる。他方、標準モデルがすべてのフ レーズに相当する場合、標準モデルは、システムによっ て学習されるべき種々のフレーズのそれぞれに必要とな る。また、この利点に加えて、ワードに相当する標準モ デルを用いると、フレーズのワード間の間隔に対するシ

ステムの柔軟性が増す。これは、フレーズの始めまたは 終わりおよびフレーズのワードの間に現れる環境モデル によって可能になる。

【0165】さらに他の実施形態において、モデルの連続フレームが類似する場合、標準モデルは圧縮される。標準モデルが圧縮されると、類似の連続フレームは、1つのフレームに置き換えられる。このような実施形態において、入力発声音の連続フレームが2回までしかワードモデルの同じステートに関連付けられないというようなダイナミックプログラミングプロセスに対する制限は、除去されなければならない。

【0166】図17に示される言語モデルにおいて、あるワードに2つの異なるワードが続く場合、それら2つのワードの何れが当該ワードに続くかについて優先度はない。他の実施形態においては、いくつかのワードのシーケンスに他のシーケンスより優先度を高めるよう、重みを付けることができる。例えば、図17aに示されるフレーズについては、「make it more…」(ここで、「…」の部分には色名称が続く)というフレーズは、

「make it smaller」または「makr it larger」または「make it brighter」というフレーズより一般的であることが知られているとする。従って、この場合は、ノードN7からノードN8までの遷移が、ノードN7からノードN市までの遷移よりも強くなるように設定される。これは、ノードN7から「more」、「smaller」、「larger」、「brighter」というワードへ伝わる累積距離に重み付けを行う重み係数を用いることによって達成される。

【0167】当業者には明らかなように、許容されたワードのシーケンスを決めるために用いられる言語モデルは、バイグラム(二重字)モデルである必要はないが、いかなる知られたタイプの言語モデル、例えば定型文法モデルでもよい。用いられた言語モデルのタイプが変更される場合、上記のダイナミックプログラミングマッチングプロセスにはいくつかの変更が必要となるが、このような改造は、音声認識の当業者には明らかである。しかしながら、マッチングプロセスの重要な特徴部分は変化されないままとなる。どんなパターンの合致プロセスにも合うように設計されているからである。

【0168】第1の実施形態において、あるワードの標準モデルを生成する前に、そのワードを含む少なくとも2つのフレーズが入力されなければならない。これは、操作上の好ましい方法であり、ワードモデルを、そのワードを含む1つのフレーズ例のみから各ワード毎に発生させることもできる。しかしながら、このような実施形態によって得られる標準モデルは、どのようなフレーズが与えられた場合でも、あまり典型的なものとはならない。さらに、第1の実施形態で用いられた学習方法において、1つのワードに対していったん標準モデルを決定すると、ワードモデルは、次の入力学習フレーズがその

ワードを含むかどうかに関らず、変更されない。他の実施形態においては、すでにワードモデルがあるワード例を含む入力フレーズを用いて、学習セッション中に既存のワードモデルを更新することを可能とする。

【0169】ユーザが音声認識システムを学習させて、 既に分離して入力された複数のワードを含むフレーズを 入力すると、システムは、それらのワードについて分離 した状態で再度入力するようユーザに促すことはしな い。これに対して、他の実施形態においては、システム は、ユーザにそのようなワードを再度入力するよう促 し、ワードの2つの発声音が大して違わないことを確認 するべくチェックを実行する。

【0170】第1の実施形態において、標準モデルが学習されたりまたは用いられる場合、ユーザはテキストを入力し、それに相当する音声コマンド入力しなければならない。音声認識の当業者には分かるように、これは必須ではない。テキストを入力する代わりに、ユーザはキーボード、ファクシミリ、複写機等の相当するキーまたはキーの組み合わせを押すようにしてもよい。例えば、複写機で用いるためにシステムに学習させる場合において、音声コマンド「copy(複写)」と入力し、これに対する所望の機械の応答は、ユーザが複写ボタンを押しさえすれば、入力される。

【0171】さらに、上記のダイナミックプログラミングマッチングプロセス、標準モデルの発生および適応プロセスを実行させる方法が、他のタイプのパターンマッチングのためにも用いられることは、パターンマッチングの当業者に明らかである。例えば、上記パターン合致プロセスは、手書き文字の認識または他のパターン合致技術で用いられることが考えられる。

【0172】連続ワード音声認識システム(文音声認識システム)は、上記の第1の実施形態に記載されているが、記載されたシステムの多くの特徴が他の種類の音声認識システムにも等しく適用できることは当業者には明らかである。例えば、分離ワードモデルを決定する方法および上記分離ワードモデルは、分離ワード音声認識システム(単語音声認識システム)で用いられる。同様に、ダイナミックプログラミングプロセスが行われる方法の多くの特徴および刈り込みしきい値が調整される方法は、いずれの音声認識システムでも用いられ、ここで標準モデルは、音声のいかなる部分、例えば音素、音節等にも対応させ得る。

【0173】第1の実施形態に記載された音声認識システムは、多くの異なるソフトウェアアプリケーション、例えばスプレッドシートパッケージ、グラフィックパッケージ、ワードプロセッサパッケージ等とともに用いることができる。音声認識システムがそのような複数のソフトウェアパッケージとともに用いられる場合、特に、各アプリケーションで用いられるフレーズが異なる場合、各パッケージ毎にワードおよび言語モデルを分ける

ことが有利である。この理由は、ワードモデルの数が増加したり、言語モデルのサイズが大きくなるにつれて、システムが入力発声音を認識するための時間が長くなるからである。したがって、各アプリケーション毎にワードおよび言語モデルを分けることによって、音声認識システムの速度を維持できる。さらに、いくつかのワードおよび言語モデルは、各アプリケーションに用いられ得る。

【0174】さらに、当業者に明らかなように、上記音声認識システムは、多くの異なるタイプのハードウェアでも用いられる。例えば、パーソナルコンピュータ等の機器で用いられるのは明らかであるが、それ以外に、音声認識システムは、ファクシミリ、電話、プリンタ、複写機等、人間と機械のインタフェースを有する各種機器のユーザインタフェースとして用いられ得る。

【0175】<適用例>上記音声認識システムの適用の1つは、コンピュータグラフィックパッケージのユーザインタフェースである。グラフィックパッケージのユーザは、複雑なポインティングデバイスまたはキーボードによるグラフィックメニューの操作を用いることなく、マイクロフォンを介して画像操作コマンドを入力できる。

【0176】図36は、音声認識システムのユーザインタフェースを有する画像編集システムのブロック図である。特に、システムは、ユーザからの音響音声コマンドをそれに相当する電気信号に変換するマイクロフォン7と、入力音声を認識するための、例えば上述したような音声認識装置(SPEECH RECOGNITION)271と、認識音声を解釈するコマンドインタプリタ(COMMAND INTERPRE TER)273と、コマンドインタプリタに応答するグラフィックパッケージ(GRAPHIC PACKAGE)275と、現在編集されている画像を表示するディスプレイ(DISPLAY)277とから構成される。

【0177】入力音声コマンドは音声認識ブロック27 1によって認識され、コマンドインタプリタ273によって解釈される。コマンドインタプリタは、ディスプレイ277に表示された画像を編集するための指示シーケンスをグラフィックパッケージ275に送る。グラフィックパッケージ275は、ユーザからの他の経路からの指示やデータを受けることができるが、これは矢印279によって示されている。

【0178】本システムは、表示された画像の色操作に役立つ。このようなシステムの機能を、図37および図38を参照して説明する。図37は、海291、空293、雲295、陸地297の風景図を示す。ユーザが海291をもっと青くしたい場合、ユーザは「make this more blue (これをもっと青くする)」というコマンドを入力し、マウスのようなポインティングデバイスを用いて、ディスプレイ277上の海291を指示する。システムは入力を認識し、グラフィックパッケージ275

は表示画像を変化させ、所望の変化を行う。図36に示されるシステムがこの処理を行う方法を、以下により詳細に説明する。

【0179】ユーザがマイクロフォン7を介して「make this more blue」というコマンドを入力すると、音声 認識装置271は発声音を表す代表的なパターンシーケ ンスに変換し、そのシーケンスを予め記憶されている既 知の、音声を示すパターンシーケンスと比較する。この 比較から、音声認識装置271は認識結果をコマンドイ ンタプリタ273に出力し、コマンドインタプリタ27 3は認識結果を解釈し、例えばハードディスクに記憶さ れた適当なプログラムを起動する。本例において、起動 されたプログラムは、グラフィックパッケージ275に 接続されたポインティングデバイス (図示されていな い)の監視を開始し、青くしなければならない対象の詳 細を受け取る。ユーザは、ポインティングデバイスによ って制御されるカーソルを海291が表示されている領 域に移動し、ポインティングデバイスの選択ボタンを押 し、その押下状態を保つ。選択ボタンの押下状態を保ち ながら、ユーザは、カーソルを、ディスプレイ277の 海291に対応する領域の全域で移動させる。カーソル が海291全体を移動するにつれて、コマンドインタプ リタ273によって起動されたプログラムは、色相の 値、カーソルによってたどられる画素の彩度および明度 を収集する。ユーザが選択ボタンを放すと、プログラム は、低い値の彩度または明度を持たないサンプル画素の 平均色相と標準偏差を決定する。

【0180】図38は、6時の位置が0°及び赤色に相 当し、10時の位置が120°及び緑色に相当し、2時 の位置が240°及び青色に相当する色相チャート30 1を示す。上記の例において、プログラムが平均色相を 40°、標準偏差を5°に決定したとすると、その結 果、色相値の範囲は、図38に示される色相チャートの 領域303によって示される。海291をもっと青くす るため、システムは、領域303内の色相値を有するす べての画素を図38に示される目標領域305に変化さ せる。目標領域305は次のようにして決定される。ま ずサンプル画素のために決定された平均色相値と青に相 当する色相値との間の最小弧を決定し(この弧は図38 の弧307によって示される)、この弧の角度を4つに 分割し、最後に本例のように、領域303内の色相値を 有するすべての画素の色相値に分割した結果の角度を加 えたり、或いは減じることによって目標領域が決定され る。本例において、平均色相は40°であり、したがっ て、弧の角度が200°なので、領域303内にあるす べての画素の色相値から50°が減じられる。画像は再 表示され、海291はユーザに「より青い」を示す。

【0181】当業者には分かるように、与えられた色に 相当する特定の色相値を持たせるために、領域303に ある色相範囲を有するすべての画素を変化させることが できる。1つのパレットの色をユーザが作ったパレット の色に関連付けることができるので、ユーザは、機器に ユーザが定義したパレットの1つをロードすることを依 頼すれば良い。もとの画像の色は、ユーザ定義パレット の相当する色に変化される。代わりに、同様の処理技術 を用いて、画像の一部または複数部分の明度または彩度 を変更することができる。この処理は、例えば出力がフ ァクシミリ機器からの白黒画像であり、ユーザが再生画 像の部分の色調のコントラストを強調したい場合にも好 適である。上記の実施形態では画像再生にディスプレイ を用いているが、システムがファクシミリ機器または複 写機とともに用いられるような場合、このようなディス プレイはオプションであることは明らかである。グラフ ィック操作システムはコンピュータに関連して説明され ているが、カメラ、特にディジタルモーション/スチー ルカメラのような画像装置にも適用できる。

【0182】以上のように、ユーザは、色編集用語また は色操作ツールを用いることなく、画像を編集できる。

【0183】また、本発明は上記実施形態によって限定されるものではなく、種々の変形および実施形態が当業者には明らかである。

【0184】なお、本発明は、複数の機器(例えばホストコンピュータ、インタフェイス機器、リーダ、プリンタなど)から構成されるシステムに適用しても、一つの機器からなる装置(例えば、複写機、ファクシミリ装置など)に適用してもよい。

【0185】また、本発明の目的は、前述した実施形態の機能を実現するソフトウェアのプログラムコードを記録した記憶媒体を、システムあるいは装置に供給し、そのシステムあるいは装置のコンピュータ(またはCPUやMPU)が記憶媒体に格納されたプログラムコードを読出し実行することによっても、達成されることは言うまでもない。

【0186】この場合、記憶媒体から読出されたプログラムコード自体が前述した実施形態の機能を実現することになり、そのプログラムコードを記憶した記憶媒体は本発明を構成することになる。

【0187】プログラムコードを供給するための記憶媒体としては、例えば、フロッピディスク、ハードディスク、光ディスク、光磁気ディスク、CD-ROM、CD-R、磁気テープ、不揮発性のメモリカード、ROMなどを用いることができる。

【0188】また、コンピュータが読出したプログラムコードを実行することにより、前述した実施形態の機能が実現されるだけでなく、そのプログラムコードの指示に基づき、コンピュータ上で稼働しているOS(オペレーティングシステム)などが実際の処理の一部または全部を行い、その処理によって前述した実施形態の機能が実現される場合も含まれることは言うまでもない。

【0189】さらに、記憶媒体から読出されたプログラ

ムコードが、コンピュータに挿入された機能拡張ボードやコンピュータに接続された機能拡張ユニットに備わるメモリに書込まれた後、そのプログラムコードの指示に基づき、その機能拡張ボードや機能拡張ユニットに備わるCPUなどが実際の処理の一部または全部を行い、その処理によって前述した実施形態の機能が実現される場合も含まれることは言うまでもない。

[0190]

【発明の効果】以上説明したように本はつめによれば、 色操作を表現する音声入力によって画像操作を行うこと が可能となり、容易に所望の画像操作が行える。

[0191]

【図面の簡単な説明】

【図1】本発明の一実施形態を操作するためにプログラムされ得るコンピュータの概略図である。

【図2】音声認識システムの概略構成を示すブロック図 である。

【図3】図2に示されたシステムの一部であるプリプロセッサの構成を示すとともに、入力音声信号に行われる処理ステップを示すブロック図である。

【図4】入力音声信号S(t)を一連の時間フレーム (FRAME)に分割した状態を示す図である。

【図5】1 つの時間フレームの典型的な音声信号例を示 す線図である。

【図6】図5に示される音声信号の離散フーリエ変換の 振幅応答を示す図でる。

【図7】メルスケールフィルタバンクの平均振幅応答出力を示す図である。

【図8】メルスケールフィルタバンクからの出力の対数 振幅スペクトルを示す図である。

【図9】図8に示される対数振幅スペクトルのセプスト ラムを示す図である。

【図10】学習処理中に用いられる標準モデル構築部の 恒星を示すブロック図である。

【図11】音声認識システムで用いるワードモデルを発生させるための学習処理中に行われる処理を示すフローチャートである。

【図12】学習処理中に学習フレーズおよび学習ワード が記憶される一形態例を示す図である。

【図13】複数の入力フレーズ及び入力ワードと、それらのフレーズ及びワードに対応するパラメータフレームシーケンスを示す図である。

【図14】学習処理中に入力された入力発声音からワー ドモデルを決定するための処理を示すフローチャートで ある。

【図15】端の部分が切り捨てられた学習ワード及びそれに対応するパラメータフレームシーケンスを示す図である。

【図16】図15に示されるワードのパラメータフレームと、そのワードが含まれる入力フレーズのパラメータ

フレームとの関連付けを示す図である。

【図17A 】複数の入力フレーズ例を学習処理している間に発生された言語モデル例を示す図である。

【図17B】システムが新しいフレーズを言語モデル に追加する方法を示すフローチャートである。

【図18】ダイナミック処理技術を用いて入力ワードが ワードモデルに関連付けられる際の処理を説明する図で ある。

【図19】ある入力フレームから次の入力フレームのステートへの許可された移行シーケンスを示す図である。

【図20】図19に示される許容された状態移行シーケンスの他の例を示す図である。

【図21】第1の実施形態で用いられるダイナミックプログラミングアラインメント技術の実行手順を示すフローチャートである。

【図22】ワードモデル、現アクティブリストおよびそれらに関連する新アクティブリストを示す概略図である

【図23】標準モデル内で伝わるダイナミックプログラミングパスの複数の例を示す図である。

【図24】図21のステップ847に含まれる処理を示すフローチャートである。

【図25】図23で示された2つのダイナミックプログラミングパスが現入力フレームから次の入力フレームに伝わる方法を説明する図である。

【図26A】図22に示されるワードモデルの現アクティブリストの第1の状態が処理された後の新アクティブリストの内容を示す図である。

【図26B】図22に示されるワードモデルの現アクティブリストの第2の状態が処理された後の新アクティ

ブリストの内容を示す図である。

【図27A 】図24のステップS77で行われる処理 を示すフローチャートである。

【図27B 】図24のステップS77で行われる処理 を示すフローチャートである。

【図28】図21のステップS51で行われる処理を示 すフローチャートである。

【図29】図28に示される処理中において、ノードN に対して行われる処理を示す図である。

【図30】図21のステップS57で行なわれる処理を示すフローチャートである。

【図31】図22に示されるワードモデルのエントリステートを示す図である。

【図32】図21のステップS65で行われる処理を示すフローチャートである。

【図33】入力フレーズのパラメータフレームシーケンスと、入力フレーズ内に含まれるワードの分離的発声によるパラメータフレームシーケンスとを示す図である。

【図34】他の実施形態による第1の代替技術を用いて、ワードモデルを異なるユーザに適用するための処理を示すフローチャートである。

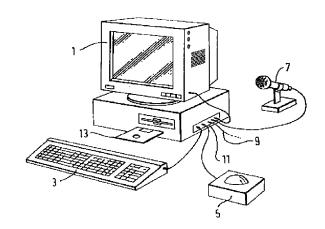
【図35】他の実施形態による第2の代替技術を用いて、ワードモデルを異なるユーザに適用するための処理を示すフローチャートである。

【図36】音声認識ユーザインタフェースを有する画像 編集システムのブロック図である。

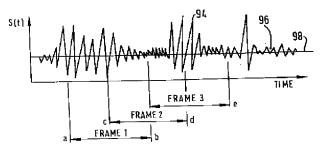
【図37】海、空、雲および陸地を含む風景図の表示例 を示す図である。

【図38】円周上に表される色相チャートを説明する図 である。

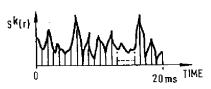
【図1】

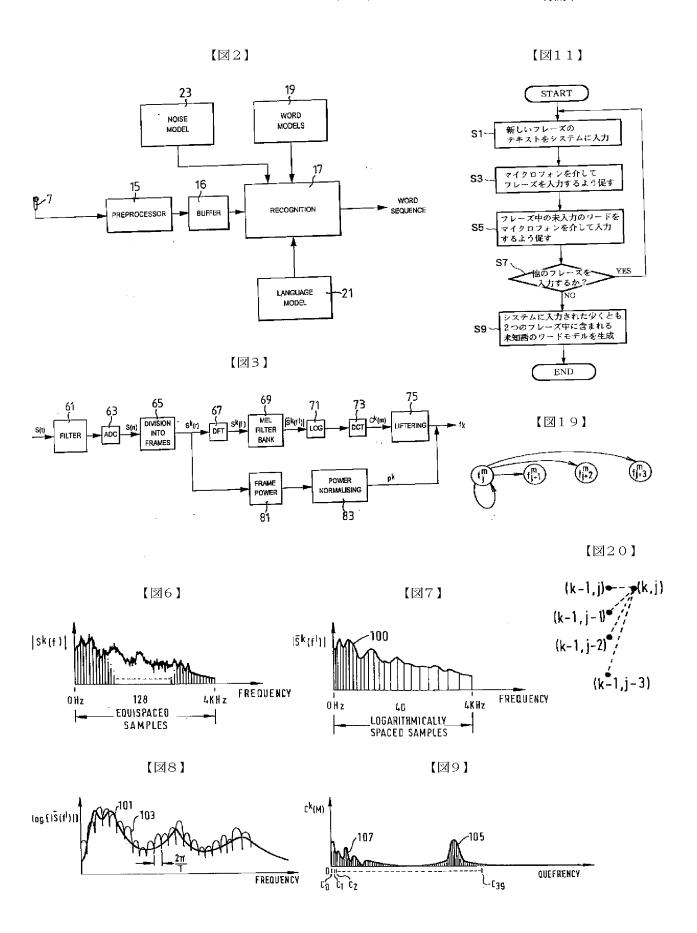


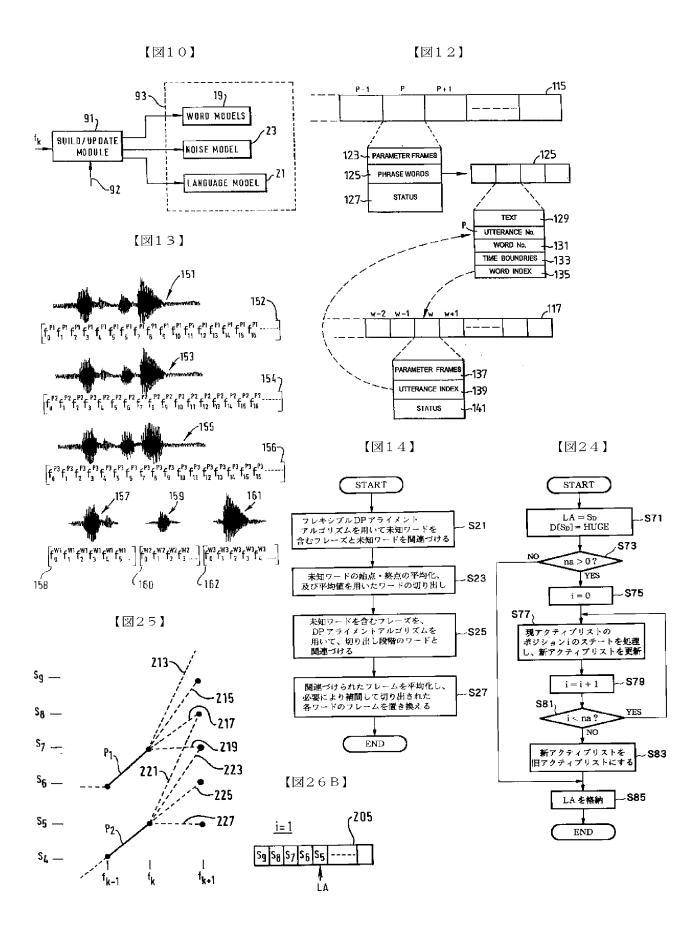
【図4】

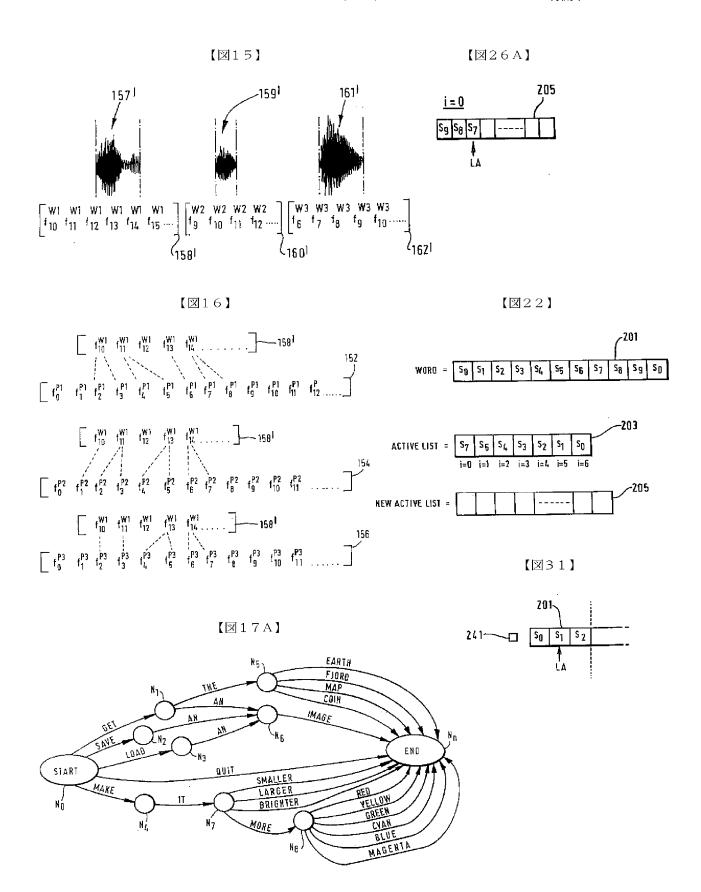


【図5】

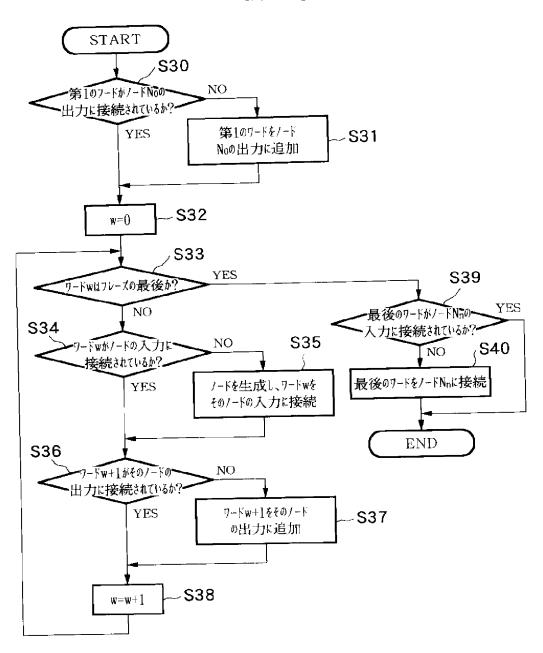


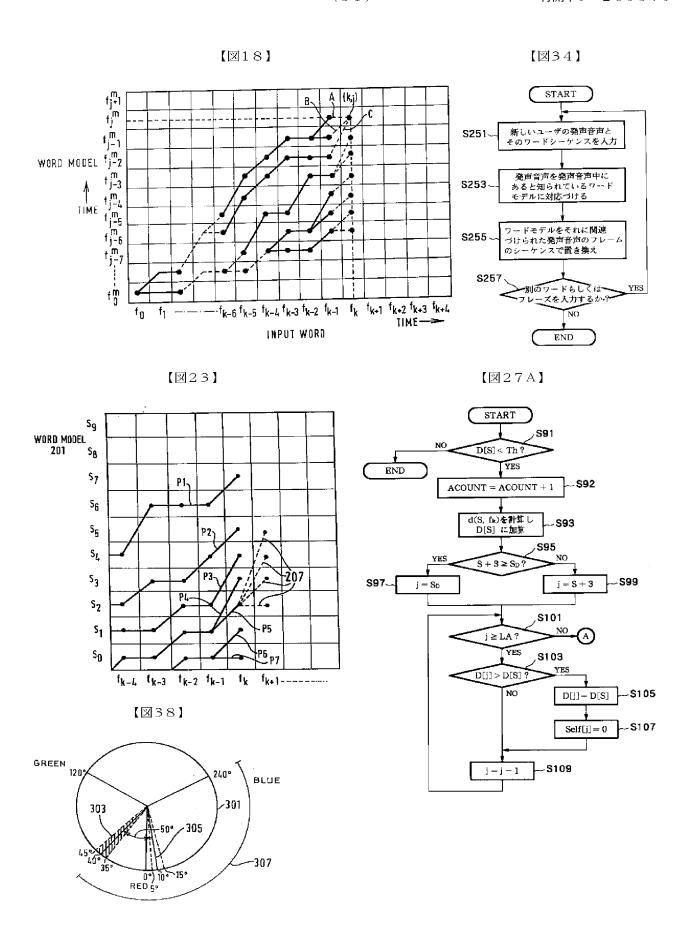




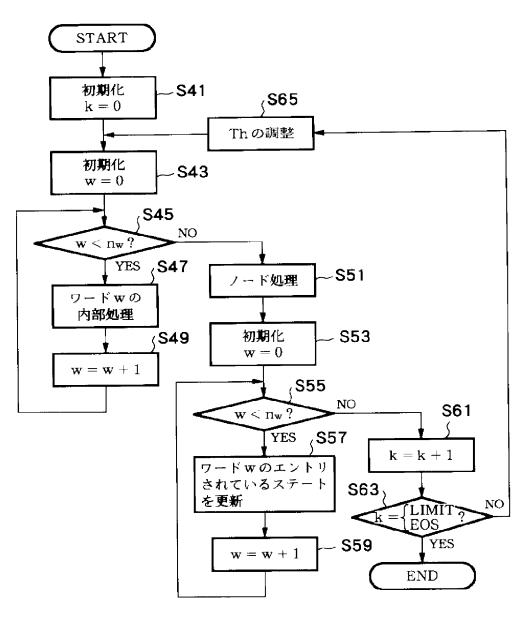


【図17B】

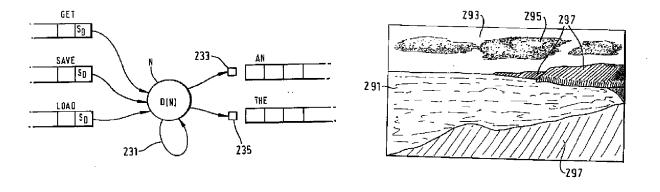


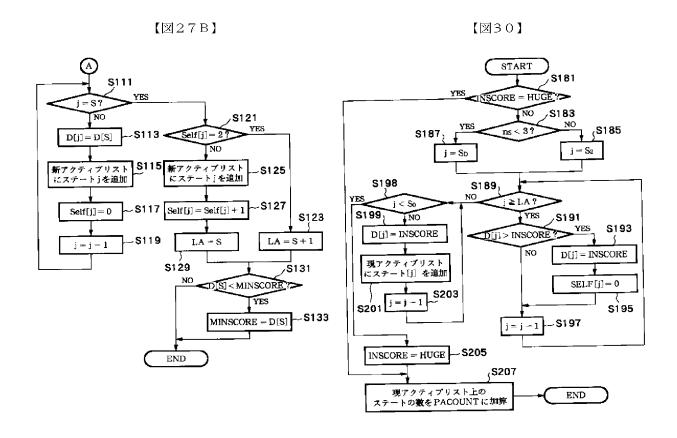


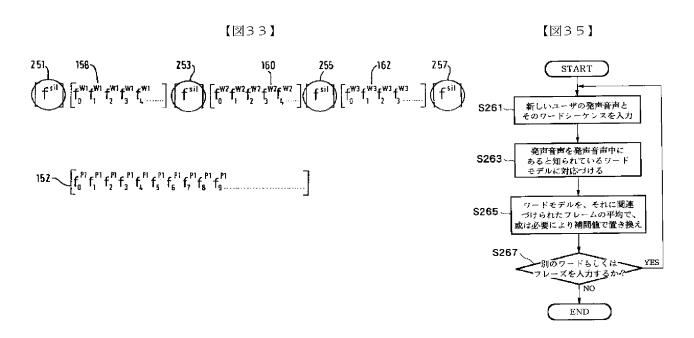
【図21】



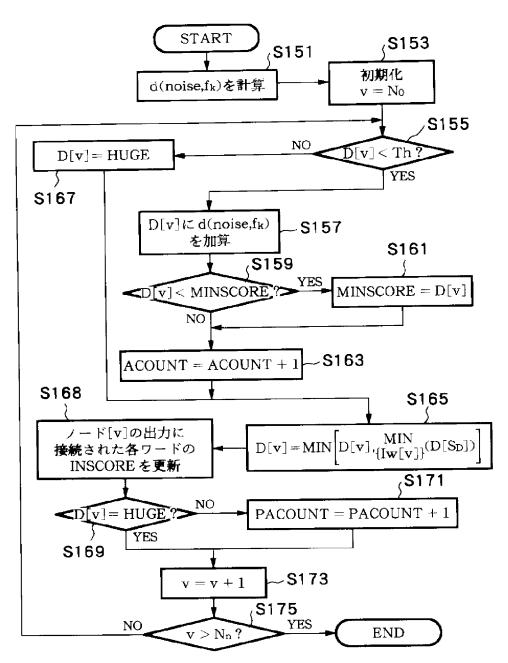
【図29】 【図37】



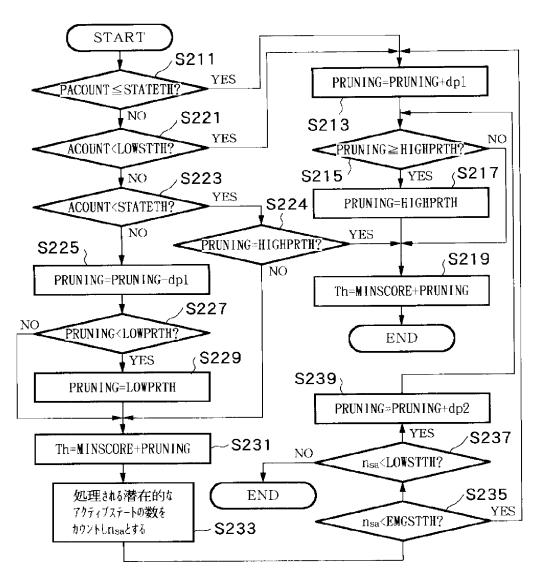




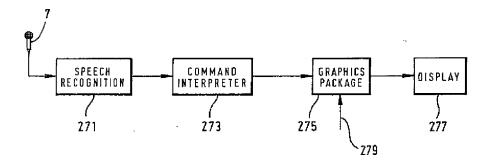
【図28】



【図32】



【図36】



フロントページの続き

 (51)Int.Cl.6
 識別記号
 庁内整理番号
 F I
 技術表示箇所

 G10L 3/00
 551
 G06F 15/62
 310A